



Pro gradu -tutkielma
Ilmakehätieteiden maisteriohjelma
Meteorologia

Lämpötilan suuret ennustevirheet Suomessa talvisin

Sini Tenhunen

12.5.2019

Ohjaajat: FM Leila Hieta ja Prof. Heikki Järvinen

Tarkastajat: Prof. Heikki Järvinen ja FM Leila Hieta

HELSINGIN YLIOPISTO
MATEMAATTIS-LUONNONTIETEELLINEN TIEDEKUNTA
PL 64 (Gustaf Hällströmin katu 2a)
00014 Helsingin yliopisto

Tiedekunta — Fakultet — Faculty		Koulutusohjelma — Utbildningsprogram — Degree programme	
Matemaattis-luonnontieteellinen tiedekunta		Ilmakehätieteiden maisteriohjelma Meteorologia	
Tekijä — Författare — Author			
Sini Tenhunen			
Työn nimi — Arbetets titel — Title			
Lämpötilan suuret ennustevirheet Suomessa talvisin			
Työn laji — Arbetets art — Level	Aika — Datum — Month and year	Sivumäärä — Sidantal — Number of pages	
Pro gradu -tutkielma	12.5.2019	51	
Tiivistelmä — Referat — Abstract			
<p>Tässä työssä perehdytään Suomessa talvisin suuria lämpötilan ennustevirheitä aiheuttaviin tilanteisiin ja pyritään löytämään yhteyksiä ECMWF:n säämallin mallimuuttujien ja suurten ennustevirheiden välille, jotta ECMWF:n sääennusteita voitaisiin jatkokäsitellä Ilmatieteen laitoksella esimerkiksi koneoppimismenetelmin. Yleisesti ECMWF:n sääennusteet toimivat Suomen alueella hyvin, mutta talvella heikkotuulisissa ja selkeissä pakkastilanteissa ennusteiden laatu heikkenee huomattavasti. Työssä todetaan, että ECMWF:n säämallin kahden metrin lämpötilalaskentaan on tehty rajoituksia, jotka heikentävät säämallin kykyä ennustaa lämpötiloja stabiileissa olosuhteissa.</p> <p>Työssä tehdään data-analyysia käyttäen Ilmatieteen laitokselle tallennettuja vuosien 2013-2017 ECMWF:n sääennustedatasta saatavilla olevia mallimuuttujia. Ennusteita verrataan Suomen alueelta valittuun 90 havaintoaseman joukkoon, jotka on jaoteltu Ilmatieteen laitoksen tilastoiman 30 vuoden keskilämpötilan mukaan kolmeen alueeseen. Aluksi mallimuuttujien ja ennustevirheiden välisiä yhteyksiä eri alueilla tutkitaan lineaaristen korrelaatioiden avulla, jonka jälkeen korrelaatiotuloksia ja empiirisiä havaintoja hyväksikäyttäen valitaan lupaavimmat mallimuuttujat tiheysfunktioanalyysiin. Tiheysfunktioanalyysissa piirretään jakaumia erilaisille ennustevirheille ja pyritään löytämään tilanteita, joissa jollakin alueella tietynlainen ennustevirheen suuruus näyttäisi liittyvän tietynlaisiin ennustettuihin mallimuuttujan arvoihin.</p> <p>Oletuksena on, että yliennustustilanteet erottuisivat tiheysfunktio kuvista parhaiten, sillä suurimmat ja tyypillisimmät lämpötilan ennustevirheet ovat talvisin yliennustevirheitä, jolloin säämallin ennustama lämpötila on lämpimämpi kuin havaittu lämpötila. Tuloksena kuitenkin nähdään, että eroavaisuuksia eri lämpötilavirheiden välillä näkyy paljon odotettua vähemmän ja vain muutamien mallimuuttujien kohdalla hieman selkeämmin. Dataa ja havaintoaineistoa tarkemmin analysoitaessa havaitaan, että yliennustustilanteet tapahtuvat todennäköisemmin juuri kylmässä korkeapainesäässä, jossa taivas on pilvetön ja tuuli heikkoa. Tällöin siis empiirisesti havaittu ilmiö voidaan todeta myös data-analyysin keinoin. Vaikka jonkinlaista parannusta ECMWF:n ennusteeseen voidaan jatkokäsittelyllä tehdä, tulee pidempikantoinen ratkaisu kuitenkin itse säämallin kehityksestä. Jatkotoimenpiteenä voitaisiin suorittaa tarkempaa data-analyysia käyttämällä dataa luokittelevia tekoälyalgoritmeja, sekä suodattaa lämpötilavirhe aikasarjaa ilmiökohtaisempaa tutkimusta varten.</p>			
Avainsanat — Nyckelord — Keywords			
ECMWF, säämalli, lämpötilan ennustevirhe, yliennustaminen, aliennustaminen, mallimuuttuja			
Säilytyspaikka — Förvaringsställe — Where deposited			
Muita tietoja — Övriga uppgifter — Additional information			

Sisältö

1	Johdanto	1
2	ECMWF:n säämalli ja kahden metrin lämpötilan ennustaminen Suomessa talvisin	3
2.1	Kahden metrin lämpötilaennusteen haasteet Suomessa	3
2.2	ECMWF:n säämalli ja kahden metrin lämpötilaennuste	6
2.2.1	Suuria lämpötilan ennustevirheitä aiheuttavat olosuhteet	7
3	Käytetty data ja aineisto	16
3.1	Valittu havaintoasemajoukko	16
3.2	MOS-tietokannan ECMWF:n data	16
3.2.1	ECMWF:n merkkikäytäntö säteilymuuttujille	19
4	Käytetyt menetelmät	20
4.1	Havaintoasemajoukon jaottelu	20
4.2	Lämpötilan ennustevirheen jakaminen luokkiin	21
4.3	Data-analyysimenetelmät	23
5	Mallimuuttujien välinen lineaarinen korrelaatio ja jakaumat lämpötilan ennustevirheen suhteen	24
5.1	Mallimuuttujien ja lämpötilavirheen välinen lineaarinen korrelaatio	24
5.2	Mallimuuttujien jakaumat lämpötilan ennustevirheen suhteen	28
5.2.1	Merkittävimpien mallimuuttujien jakauma lämpötilan ennustevirheen suhteen inversiolle suotuisissa olosuhteissa	39
6	Johtopäätökset	42
7	Yhteenveto	43
	Kiitokset	45
	Kirjallisuutta	46
	Liite A Asemien tiedot	

1. Johdanto

Talvisin kahden metrin lämpötilan ennustaminen on Suomessa huomattavasti vaikeampaa kuin kesällä johtuen Suomen pohjoisesta sijainnista ja talvisista sääilmiöistä. Ilmatieteen laitoksella käytetään kymmenen vuorokauden sääennusteissa pääasiallisena säämallina Euroopan keskipitkien sääennusteiden keskuksen (ECMWF) säämallia, sillä sen on yleisesti todettu toimivan hyvin Suomen olosuhteissa ja ilmastossa jokaisena vuodenaikana. On kuitenkin havaittu, että talvella säämallin lämpötilaennusteen laatu voi olla välillä hyvinkin heikko, jolloin syntyvät lämpötilan ennustevirheet voivat olla jopa lähes ± 20 °C.

Nämä suuret ennustevirheet toimivat myös tämän työn motivaationa. Työn tarkoituksena on löytää yhteyksiä ECMWF:n mallimuuttujien ja suurten ennustevirheiden välille, jotta tietoa voidaan hyödyntää Ilmatieteen laitoksella säämallin jälkikäsitteilyssä muun muassa koneoppimismenetelmin. Tällöin voitaisiin tunnistaa suuria ennustevirheitä aiheuttavat olosuhteet ja tilanteet etukäteen, jolloin sääennusteiden laatua voitaisiin mahdollisesti parantaa. Empiiristen havaintojen pohjalta voidaan sanoa, että kylmissä, heikkotuulisissa ja selkeissä korkeapainetilanteissa syntyy suuria ennustevirheitä, mikä tukee myös kirjallisuudessa tehtyjä havaintoja (Haiden et al., 2014b, 2018). Nämä ennustevirheet ovat yleensä yliennustevirheitä, jolloin säämallin ennustama lämpötila on liian lämmin verrattuna havaittuun lämpötilaan. Työssä perehdytään myös ECMWF:n säämallin kahden metrin lämpötilaennusteen tuottamiseen: miten säämalli laskee tämän diagnostisen mallimuuttujan arvon, sekä millaisia ongelmia ja rajoitteita siihen liittyy.

Lämpötilan ennustevirheitä voi varsinkin talvisin syntyä monen ilmiön kautta. Suomessa talvisin auringonsäteilyn ja vuorokausivaihtelun puuttuessa maanpinnan tehokas ulossäteily voi saada aikaan matalan kerroksen inversioita, joihin liittyy lämpötilan ylienustamista (Hyrkkänen et al., 2015; Haiden et al., 2014b). Huomataan myös, että pilvipeitteessä tapahtuvat ennustamattomat tai ennustetutkin muutokset voivat saada aikaan sekä suuria yli- että aliennustamistapauksia: todellisuudessa pilvipeitteen äkillisesti repeillessä kahden metrin lämpötilat lähtevät nopeasti voimakkaaseen laskuun, toisaalta säämalli saattaa ennustaa pilvisyyden muutokset oikein, mutta tilanteeseen liittyvän kylmenemisen tai lämpenemisen esimerkiksi liian heikkona.

Tässä työssä tutkimusta tehdään data-analyysin avulla. Käytössä on Ilmatieteen

laitoksen tietokannoissa olevaa ECMWF:n säämallidataa talvikuukausilta vuosilta 2013-2017 sekä lämpötilan havaintoaineisto valituilta yhteensä 90:ltä Suomen havaintoasemalta. Data-analyysissa tutkitaan aluksi lineaaristen korrelaatioiden avulla lämpötilan ennustevirheen yhteyttä ECMWF:n mallimuuttujiin. Näistä saatavaa tietoa ja empiirisiä havaintoja hyväksikäyttäen suoritetaan tiheysfunktioanalyysia ydinestimoinnilla valituille mallimuuttujille. Ydinestimoinnissa lämpötilan ennustevirhe jaetaan ennustevirheen suuruuden perusteella luokkiin, jonka jälkeen ennustettuja mallimuuttujien arvoja verrataan näihin luokkiin. Empiiristen havaintojen perusteella voidaan olettaa, että erityisesti ylienustusvirheet tulisivat korostumaan tiheysfunktioanalyysissa.

Tämä työ on jaoteltu yhteensä neljään käsittelylukuun: luvussa 2 kerrotaan Suomessa talvisin suuria lämpötilan ennustevirheitä aiheuttavista tilanteista sekä perehdytään ECMWF:n säämallin kahden metrin lämpötilan laskentaan. Luvussa 3 kerrotaan työssä käytettävästä havaintoasemajoukosta ja ECMWF:n datasta. Luvussa 4 valaistetaan käytettäviä data-analyysimenetelmiä ja luvussa 5 esitellään työn varsinaiset tulokset.

2. ECMWF:n säämalli ja kahden metrin lämpötilan ennustaminen Suomessa talvisin


Tässä luvussa kerrotaan työhön liittyvää taustaa ja teoriaa. Ensimmäisessä aliluvussa 2.1 kerrotaan minkälaisiin haasteisiin olen kahden metrin lämpötilaennusteiden kohdalla törmännyt oman kokemukseni kautta päivystävänä meteorologina, sekä minkälaisiin tilanteisiin lämpötilan ennustevirheet liittyvät. Aliluvussa 2.2 perehdytään ECMWF:n säämallin tuottamaan kahden metrin lämpötilaennusteen laskentaan. Aliluvussa 2.2.1 tunnistetaan Suomessa talvisin suuria lämpötilan ennustevirheitä aiheuttavat olosuhteet sekä kerrotaan minkälaisia ongelmia ECMWF:n säämallissa on tällöin havaittu.

2.1 Kahden metrin lämpötilaennusteen haasteet Suomessa

Ilmatieteen laitoksella ECMWF:n säämallia käytetään kymmenen vuorokauden sääennusteissa, sillä sen on todettu olevan erittäin toimiva hyvin monessa tilanteessa niin kesällä kuin talvella, niin muuttuvissa kuin pysyvimmissäkin säätyypeissä (Magnusson and Källén, 2013). Talvella Suomessa ECMWF:n säämallilla on myös heikkoutensa, sillä tietätyt tyypisissä säätilanteissa lämpötilan ennustevirheet voivat olla laajalti yli kymmenen astetta, vaikka normaalisti säämalli toimiikin hyvin.

Suomessa vallitsee talvisin tilanne, jolloin lämpötilan vuorokausivaihtelu ja pinnalle tuleva auringonsäteily puuttuvat käytännössä kokonaan (Pirinen et al., 2012). Pinnan nettoauringsäteily tarkoittaa maan pintaan ja siitä pois lähtevän lyhytaaltoisen säteilyn säteilytasetta (AMS Glossary, 2012; Stull, 1988, s. 555). Pinnan nettoauringsäteilyn ollessa positiivinen maanpinta saa enemmän lyhytaaltosäteilyä kuin maanpinnalta lyhytaaltosäteilyä poistuu (AMS Glossary, 2012). Kuvassa 2.1 on piirretty tässä työssä käytetystä datasta (datasta tarkemmin luvussa 3) maanpinnan nettoauringsäteilyn jakauma talvella eli joului-, tammi- ja helmikuussa. Kuvasta nähdään, että pinnan hetkellinen net-

toauringsäteily on enimmäkseen $0-2 \text{ W/m}^2$ tätä suurempien lukemien osuuden ollessa silmämääräisesti tarkasteltuna alle 10 prosenttia. Myöhemmin työn tuloksia tarkastellessa voidaan tämän kuvan nojalla sanoa niiden kuvaavan tilanteita, jolloin hetkellinen pinnan nettoauringsäteily on ollut noin 0 W/m^2 . Vertailun vuoksi keskimääräinen hetkellinen auringonsäteilyn voimakkuus Suomessa on kesäisin noin $350-600 \text{ W/m}^2$ riippuen ajankohdasta ja paikasta (Pirinen et al., 2012).




Kuva 2.1: Pinnan nettoauringsäteilyn jakauma työssä käytetystä datasta piirrettynä. Jakaumasta nähdään, että reilusti suurin osa nettoauringsäteilystä on ollut välillä $0-2 \text{ W/m}^2$. Voidaan todeta, että tässä tutkimuksessa tulokset kuvaavat tilanteita, jolloin pinnan nettoauringsäteily on käytännössä puuttunut kokonaan.

Lämpötilan vuorokausivaihtelun ja pinnan nettoauringsäteilyn puuttuessa kahden metrin lämpötilan suuret ajalliset ja paikalliset vaihtelut ovat mahdollisia ja jopa todennäköisiä, mikä tekee ennustamisesta haastavaa. Auringon lämpötiloja tasaavan vaikutuksen puuttuessa talvella pilvisyyden vaihtelu voi aiheuttaa huomattavia lämpötilan ennustevirheitä. Pilvisyyden odottamaton rakoilu kylmässä tilanteessa saa kahden metrin lämpötilat romahtamaan laskuun. Pilvisyyden runsastuminen johtaa usein vastaavasti lämpötilojen lauhtumiseen, sillä pilvipeite emittoi pitkäaaltosäteilyä takaisin pinnalle, jolloin tehoisan ulossäteilyn määrä vähenee (NASA, 1999). Tällaisissa tilanteissa säämalli on tyypillisesti liian kylmä, jolloin ECMWF:n ennustamat lämpötilat ovat aliennustettuja (Haiden et al., 2018). Pilvisyys on lisäksi hankala ennustaa, mikä lisää suurien ennustevirheiden todennäköisyyttä (Hyrkkänen et al., 2015).

Hyvin kylmissä lämpötiloissa ECMWF:n säämallin ennustamat lämpötilat ovat tyy-

pillisesti havaittuja lämpimämpiä eli yliennustettuja (Haiden et al., 2018; Finnish Meteorological Institute, 2018). Tämä nähdään erityisen hyvin kuvasta 2.2, jossa vaaka-akselilla on havaittu lämpötila ja pystyaskelilla ECMWF:n ennustama kahden metrin lämpötila talvikuukausilta 2013-2017 ja ennustepituuksilta 3-48 tuntia. Harmaat ympyrät kuvaavat yksittäisiä havainto-ennustepareja, punaisella viivalla on piirretty “täydellinen ennuste”, jossa havainto vastaa täysin ennustettua lämpötilaa. Kuvasta huomataan, että havaittujen lämpötilojen ollessa talvella lähellä nollaa harmaat ympyrät ovat enemmän punaisen viivan alapuolella, jolloin säämallin ennustamat lämpötilat ovat hieman aliennustettuja. Erityisesti kuvasta nähdään, että mitä kylmempi lämpötila, sitä enemmän ECMWF:n ennustamat lämpötilat ovat punaisen viivan yläpuolella eli yliennustettuja. Nähdään myös, että hajonta kasvaa lämpötilan kylmetessä, jolloin ennusteessa on enemmän virhettä ja ennustettavuus on heikompi.

Ilmatieteen laitoksella kahden metrin lämpötilaennustetta verifioidaan säännöllisesti ja sitä varten on kehitetty ennustevirherajat, jotka vaihtelevat havaitun lämpötilan mukaan. Taulukosta 2.1 nähdään, että talvella suhteellisen lämpimissä olosuhteissa sallitun ennustevirheen raja on pienempi kuin kylmissä olosuhteissa. Tämä kuvstaa hyvin sitä, että lämpötilojen ennustaminen on talvella haastavampaa kuin kesällä. Työssä käytetystä datasta kerrotaan tarkemmin luvussa 3.



Kuva 2.2: ECMWF:n ennustama lämpötila havaitun lämpötilan funktiona talvikuukausilta 2013-2017 ja ennustepituuksilta 3-24 tuntia.. Punainen viiva kuvaa “täydellistä ennustetta”, jossa havainto vastaa täysin ennustettua lämpötilaa, harmailla ympyröillä on esitetty havainto-ennustepareja. Huomataan, että mitä kylmemmät havaitut lämpötilat ovat, sitä enemmän ennustettu lämpötila on punaisen viivan yläpuolella, mikä tarkoittaa mallin taipuvaisuutta yliennustaa lämpötiloja kyseisissä lämpötiloissa. Havaittujen lämpötilojen ollessa nollaa celsiusastetta lämpimämpiä ECMWF:n säämalli puolestaan keskimäärin aliennustaa lämpötiloja.

Taulukko 2.1: Sallittu lämpötilan ennustevirheen suuruuden riippuvuus havaitusta lämpötilasta

Havaittu lämpötila	Sallittu lämpötilan ennustevirhe
$< -15^{\circ}\text{C}$	$\pm 5^{\circ}\text{C}$
$-5 \dots -15^{\circ}\text{C}$	$\pm 3.5^{\circ}\text{C}$
$> -5^{\circ}\text{C}$	$\pm 2.5^{\circ}\text{C}$


Lumipeitteen ennustamiseen ja mallintamiseen liittyvät ongelmat vaikuttavat suoraan kahden metrin lämpötilaennusteeseen. Tyypillisesti lumipeitteen vaikutuksesta ECMWF:n säämalli yliennustaa pohjoisten, erityisesti arktisten alueiden minimilämpötiloja (Arduini, 2019). Lumipeitteen vaikutuksen tarkempi arviointi kahden metrin lämpötilaennusteeseen jätetään kuitenkin tämän työn ulkopuolelle.

2.2 ECMWF:n säämalli ja kahden metrin lämpötilaennuste

ECMWF:n säämalli on globaali säämalli, jonka horisontaalinen hilaväli on päivitetty vuonna 2016 16 kilometristä yhdeksään kilometriin (ECMWF, 2016). Koska ECMWF:n säämalli ei ennusta kahden metrin lämpötilaa suoraan ajan funktiona, on se niin sanottu diagnostinen suure. Kahden metrin lämpötilaennuste interpoloidaan säämallin kahden prognostisen eli ajassa ennustettavan mallimuuttujan painotetusta keskiarvosta, jotka ovat tässä tapauksessa alimman mallipinnan eli kymmenen metrin lämpötila ja maanpintalämpötila (van Meijgaard et al., 2008; ECMWF, 2009, s. 53). Painokerroin johdetaan käyttämällä stabiilisuudesta riippuvaa profilia, jossa stabiilisuus huomioidaan $\frac{z}{L}$ avulla, missä z on korkeus maanpinnasta ja L Obukhovin pituus (van Meijgaard et al., 2008; Haiden et al., 2014b). Stabiileissa olosuhteissa L menee lähelle nollaa, jolloin $\frac{z}{L}$ kasvaa hyvin suureksi. Jotta epärealistisia profiilifunktioita ei esiintyisi, mallissa on jouduttu tekemään rajoite: $\frac{z}{L} \leq 5$ jolloin $L \geq 0.4$ (van Meijgaard et al., 2008; Haiden et al., 2018). Käytännössä näillä rajoituksilla ”pakotetaan” kahden metrin lämpötilaennuste vastaamaan hyvin stabiileissa olosuhteissa alinta mallipintaa, eli kymmentä metriä (van Meijgaard et al., 2008; Haiden et al., 2014b). Kahden metrin lämpötilaennusteeseen liittyy paljon sellaista laskentaa, jonka toimivuus riippuu täysin vallitsevista olosuhteista. Näin ollen kahden metrin lämpötilaennusteen laatu vaihtelee ja on selvää, että mallin rajoitteesta johtuen ennusteen laatu on heikompaa stabiileissa, talvella yleensä kylmissä olosuhteissa, mikä havaittiin empiirisesti aliluvussa 2.1. ECMWF on reagoinut ongelmaan testailemalla joitain muutoksia säämallin kahden metrin lämpötilakäsittelyyn, mikä paransi ennustetta pohjoisessa, mutta huononsi tropiikissa. Näiden muutosten suunta ei tuonut toivottua tulosta ja testatut muutokset hylättiin (Haiden et al., 2014a).


2.2.1 Suuria lämpötilan ennustevirheitä aiheuttavat olosuhteet

ECMWF:n säämalli ennustaa Suomessa kahden metrin lämpötiloja kokonaisuudessaan hyvin myös talvikaudella (Hyrkkänen et al., 2015). Kuvassa 2.3 on ECMWF:n säämallin 3-48 (kolmesta neljäänkymmeneenkahdeksaan) tunnin lämpötilaennusteen virheen ($T_{ennuste} - T_{havaittu}$) histogrammi 90:ltä Suomen havaintoasemalta talvilta 2013-2017. Tästä ja havaintoaineistosta kerrotaan enemmän luvussa 3. Kuvassa x-akselilla on lämpötilan ennustevirheen suuruus ja y-akselilla arvojen määrä. Kuvasta nähdään, että suurin osa arvoista on lähellä nollaa, ja vaikka säämalli keskimäärin lievästi aliennustaa lämpötiloja, on virhe silti pääosin pieni. ECMWF:n säämalli toimii siis Suomessa talvisin pääasiassa erittäin hyvin. Tässä työssä ollaan kuitenkin kiinnostuneita suurista ennustevirheistä. Kuvan 2.3 suurimpia lämpötilavirheitä tarkastellessa nähdään, että suuret lämpötilan yliennustevirheet ovat aliennustevirheitä todennäköisempiä, sillä niitä tapahtuu keskimäärin aliennustevirheitä enemmän ja virheen suuruus verrattuna aliennustevirheisiin voi olla paljon isompi (Hyrkkänen et al., 2015).



Kuva 2.3: Lämpötilan ennustevirheen jakauma talvikuukausina. Käytetty data on ECMWF:n säämallin 3-48 tunnin lämpötilaennusteen virheestä ($T_{ennuste} - T_{havaittu}$) piirretty. Havaintoaineisto on saatu Suomen 90:ltä havaintoasemalta. Säämallin dataa ja havaintoaineistoa on käytetty ajalta 2013-2017. Kuvasta huomataan säämallin keskimäärin lievästi aliennustavan lämpötiloja. Koska virhe on yleisesti hyvin pieni, ECMWF:n säämalli toimii pääasiassa hyvin Suomessa talvella. Suuria ennustevirheitä tarkastellessa yliennustevirheet ovat aliennustevirheitä todennäköisempiä.


Yleisen säöpävystyskokemuksen perusteella lauhtuminen ja jäähtyminen on ECMWF:n mallissa ennustettu lähipäivien ennusteissa useimmiten varsin hyvin, mutta pienet ajoitusvirheet voivat aiheuttaa hetkellisesti suuria lämpötilan ennustevirheitä. Kuvassa 2.4 on esimerkkitalanne pakkasen kiristymisen ja lauhtumisen aiheuttamasta lämpötilan ennustevirheestä 24 tunnin ennustejaksolla. Kuvassa on Kuopion lentoaseman havaitut lämpötilat merkitty sinisillä timanteilla ja ECMWF:n säämalleri 24 tunnin lämpötilaennuste punaisella yhtenäisellä viivalla. Ennusteet ja havainnot ovat ajalta 30.12.2018 - 3.1.2019. Kuvasta nähdään kuinka ECMWF:n säämalleri on 30.12 ja 31.12 ennustanut pakkasen kiristymisen tapahtuvaksi nopeammin kuin se todellisuudessa tapahtui. Ajanhetkellä 31.12.2018 kello 12 UTC lämpötila on todellisuudessa saavuttanut kylmimmän lukeman, vaikka lämpötilaennusteen mukaan lämpötilan pitäisi lauhtua. Lämpötilan ennustevirhe kyseisellä ajanhetkellä on noin kolme celsiusastetta. Vaikka ennustemallit pysyvätkin ennustamaan melko hyvin säätyypin muutoksia lyhyissä ennusteissa, voivat lauhtumiseen ja pakkasen kiristymiseen liittyvät ajalliset ennustevirheet aiheuttaa suuria virheitä asemakohtaisiin ennusteisiin.




Kuva 2.4: Lauhtumiseen ja pakkasen kiristymiseen liittyvä lämpötilan ennustevirhe Kuopion lentoasemalla 30.12.2018 - 3.1.2019 välisenä aikana. Yhtenäisellä punaisella viivalla on ECMWF:n 24 tunnin lämpötilaennuste ja sinisillä timanteilla havaittu lämpötila. Nähdään, että 30.-31.12 välisenä aikana säämalleri on ennustanut lauhtumisen ja pakkasen kiristymisen ilmiönä oikein. Todellisuudessa pakkasen on kuitenkin aluksi kiristynyt ennustettua hitaammin, mistä johtuen säämallerin ennustama lämpötila on ollut koko ennustejakson aluksi kylmempi kuin todellinen lämpötila. Todellisen lämpötilan saavuttaessa kylmimmät lukemat säämalleri on ennustanut lämpötilan jo lähteneen lauhtumaan, mikä aiheuttaa kuvan tapauksessa noin kolmen celsiusasteen lämpötilan ennustevirheen. Kuvan lähde: Ilmatieteen laitoksen verifointitietokanta

Pakkasjaksojen aikana esiintyvissä lämpötilan ennustevirhetilanteissa tilanne on yleensä joko ennustettu väärin tai ilmiötä ei ole ennustettu tarpeeksi voimakkaana. Pilvisyydessä tapahtuvat odottamattomat muutokset on esimerkki, jossa tilanne itsessään on ennustettu väärin ja joka johtaa usein hetkellisesti suuriin lämpötilan ennustevirheisiin. Talvella esimerkiksi pilvipeitteen ennustamaton repeäminen saa kahden metrin lämpötilan romahtamaan hyvin äkkiä maanpinnan ulossäteilyn päästessä helpommin avaruuteen (NASA, 1999). Esimerkki molemmista tilanteista nähdään kuvassa 2.5. Kuvassa 2.5(a) on esitetty lämpötila-, pilvisyys- ja tuulihavainnot Joensuun Lentoasemalle ajalle 27.1-28.1.2019. Vertaamalla havaittua pilvisyyttä ja havaittua lämpötilaa kuvaan 2.6(a) samalta ajanhetkeltä, jossa on ECMWF-säämallin ennustama pilvisyys punaisella viivalla (ennustepituus 24 tuntia) ja havaittu pilvisyys oktissa vaaleansinisellä värillä nähdään, että säämalli on osannut ennustaa pilvipeitteen repeämisen oikein: kuvan 2.6(a) vaalealla alueella, jossa punainen käyrä (ennustettu pilvisyys) vähenee, myös havaittu pilvisyys vähenee. Tästä sään selkenemisestä johtuu kuvassa 2.5(a) näkyvä niin ennustetun kuin havaitunkin lämpötilan kylmeneminen. Huomataan kuitenkin, että säämalli ei ole osannut ennustaa kylmenemisen voimakkuutta oikein, mikä on johtanut suureen, noin kymmenen celsiusasteen, lämpötilan ennustevirheeseen.

Kuvassa 2.5(b) on esitetty samat mallimuuttujat kuin kuvassa 2.5(a) ja havaitut lämpötilat Sodankylän Lapin ilmatieteellisen tutkimuslaitoksen havaintoasemalle ajalta 11.2-12.2.2019. Kuvassa 2.6(b) on esitetty vastaavalla ajanhetkellä ECMWF:n ennustettu pilvisyys punaisella viivalla ja havaittu pilvisyys sinisen sävyillä oktissa, kun ennustepituus on 24 tuntia. Kuvasta 2.6(b) nähdään, että säämalli ei ole osannut ennustaa pilvisyyttä oikein, nimittäin pilvipeitteen revetessä 11.2.2019 kello 13 UTC lämpötilakäyrässä ei tapahdu merkittäviä muutoksia. Todellisuudessa kahden metrin lämpötila kuvassa 2.5(b) on kylmentynyt nopeasti maanpinnan voimakkaan ulossäteilyn myötä, ja aiheutuu hetkellisesti noin viiden celsiusasteen lämpötilan ennustevirhe (sininen ympyrä).




(a) Jäähtyminen ennustettu liian heikkona.




(b) Tilanne ennustettu väärin

Kuva 2.5: Yläkuvassa on Joensuun lentoaseman lämpötila-, pilvisyys- ja tuulihavainnot, sekä ECMWF:n säämallin tuottama lämpötilaennuste (ennustepituus 24 tuntia) ajalle 27.1 - 28.1.2019. Lämpötilaennuste on piirretty punaisella viivalla, lämpötilahavainnot sinisillä timanteilla, pilvisyys värillä oktaissa (asteikko oikealla) ja tuulen nopeus nuolilla (nopeusasteikko oikealla). ECMWF:n säämalli on ylemmässä kuvassa ennustanut ilmiön eli sään selkenemisen oikein, mutta siihen liittyvä kylmenemisen liian heikkona, mikä on johtanut kymmenen celsiusasteen yliennustevirheeseen. Alakuvassa on esitetty samat mallimuuttujat kuin edellä, sekä havaitut lämpötilat Sodankylän Lapin ilmatieteellisen tutkimuslaitoksen havaintoasemalta 11.2-12.2.2019. Säämalli on ennustanut tilanteen väärin ja pilvi on revennyt odottamattomasti sinisen ympyrän osoittamalla alueella. Tämä on johtanut tilanteeseen, jossa lämpötilaennustessa ei tapahtu muutosta, vaikka todellisuudessa lämpötila on lähtenyt kylmenemään heti pilvipeitteen repeytyttyä. Lämpötilan ennustevirheen suuruus on noin viisi celsiusastetta. Kuvien lähde: Ilmatieteen laitoksen verifointitietokanta



(a) Pilvisuus ennustettu oikein




(b) Pilvisuus ennustettu väärin

Kuva 2.6: Punaisella viivalla on merkitty ECMWF:n ennustama pilvisuus (ennustepituus 24 tuntia) ja sinisellä värillä havaittu pilvisuus oktaissa. Yläkuvassa ennustettu pilvisuus vastaa havaittua pilvisyyttä melko hyvin, joten säämalli on osannut ennustaa pilvisyyden oikein. Alemmassa kuvassa pilvisuus on vähentynyt äkillisesti, jolloin ennustettu pilvisuus (punainen käyrä) on ollut huomattavasti suurempi kuin havaittu pilvisuus (sinisen sävyt). Kuvien lähde: Ilmatieteen laitoksen verifiointitietokanta

Talvella Suomessa maanpinnan säteilytase on negatiivinen. Tämä aiheuttaa maan pinnan jäähtymisen, mikä lopulta johtaa myös pintaa lähimmän ilmakerroksen kylmenemiseen. Pilvet emittoivat pitkäaaltoista säteilyä maanpinnalle sitä tehokkaammin, mitä paksumpia pilvet ovat, jolloin pilvien lämmittävän vaikutuksen takia maanpinta ei tällöin pääse jäähtymään niin paljon. Jos taivas on selkeä ja pilvien lämmittävä vaikutus puuttuu, tehoisan ulossäteilyn määrä kasvaa, mikä johtaa maanpinnan nopeaan ja tehokkaaseen kylmenemiseen. Tämä voi varsinkin heikkotuulisessa pakkastilanteessa johtaa myös maanpinnan läheisen ilmakerroksen kylmenemiseen huomattavasti ylempiä ilmakerroksia kylmemmiksi, sillä stabiilisuutensa vuoksi kylmä ilma ei sekoitu ylhäällä oleviin lämpimämpiin ilmakerroksiin. Syntyy niin sanottu pintainversio, joka esiintyy yleensä matalassa kerroksessa. Tällainen tilanne syntyy usein talvella korkeapaineen aikana (Hyrkkänen et al., 2015). (Heidorn, 2012; Karttunen et al., 2008, s. 73–74)

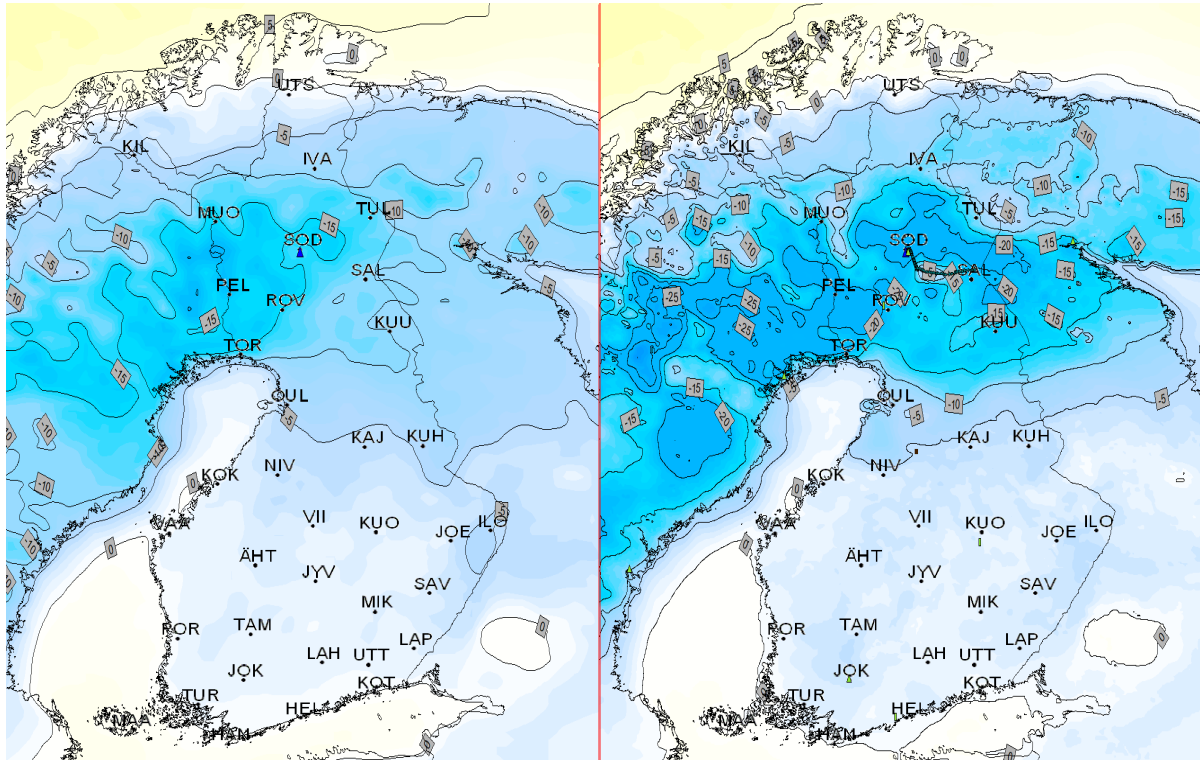
Kuvassa 2.7 on esitetty emagrammilla Sodankylän ECMWF:n ennustettu luotaus kahdella punaisen sävyllä ja havaittu luotaus sinisellä ajanhetkelle 13.12.2018 kello 00 UTC. Yhtenäinen viiva kuvaa lämpötilaprofiilia ja vastaavan värinen katkoviiva kastepistelämpötilaprofiilia. Kuvan vasemmassa reunassa on merkitty tuulivektorit eri korkeuksilla ja oikeassa reunassa arvioitu korkeus maan pinnasta kilometreissä. Kuvan alareunassa on lämpötila-asteikko. Vaaleamman punainen viiva kuvaa ECMWF:n 12.12.2018 neljästi vuorokaudessa päivittyvästä malliajosta 12 UTC-ajoa, jossa on otettu huomioon vielä kello 12 UTC havainnot samalta päivältä ennusteen alkuhetken mahdollisimman suuren tarkkuuden saavuttamiseksi. Malliluotauksesta (punaisen sävyt) nähdään, että ECMWF:n malli osaa ennustaa inversiota ilmiönä tässä tilanteessa, sillä lämpötila lähellä pintaa kasvaa korkeuden funktiona. Inversion voimakkuus ei mallissa kuitenkaan ole riittävä, sillä lämpötilan ennustevirhe ennustetun pinalämpötilan (vaaleampi punainen) ja havaitun pinalämpötilan (sininen) välillä on lähes 10 astetta. Kuvassa vaaleamman punainen viiva on suhteellisen heikosti erotettavissa sen ollessa tummemman punaisen viivan kanssa pääasiassa päällekkäin.



Kuva 2.7: ECMWF:n ennustama luotaus (punaiset sävyt) ja Sodankylässä havaittu luotaus (sininen) ajanhetkellä 13.12.2018 kello 00 UTC. Vaaleamman punaisella sävyllä on piirretty ECMWF:n kahden metrin lämpötilaennuste 12.12.2018 12 UTC -malliajon mukaan, jolloin ennustepituus on 12 tuntia. Ema-grammista nähdään, että vaikka ECMWF:n säämalli on osannut ennustaa lämpötilan inversiotilannetta ilmiönä, on se ennustanut inversion voimakkuuden todellista heikompana, sillä havaittu pintalämpötila (sininen viiva) on ollut lähes 10 astetta kylmempi kuin ennustettu pintalämpötila (vaaleamman punainen / punainen viiva).

Kuvassa 2.7 vaalean punaisella piirretyn ECMWF:n säämallin alkuhetken ja havainnon välissä on aikaa vain 12 tuntia, joten lämpötilan yliennustevirhe ei tässä tapauksessa johdu liian pitkästä ennustepituudesta, jolloin säämallin luotettavuus olisi heikko ilmakehän kaoottisen luonteen vuoksi. Inversio esiintyy matalassa kerroksessa inversion voimakkaimman osuuden ollessa alle 200 metrin paksuisessa maan pinnan läheisessä kerroksessa. Lämpötilan ennusteprofilia (punaiset sävyt) tutkimalla huomataan myös, että aivan pinnan läheisimmän kerroksen yläpuolella (noin 200 m) säämalli on ilmiötä ja sen voimakkuutta osannut ennustaa.

Kuvan 2.7 emagrammin lämpötilan havaintoprofili (sininen viiva) on ajankohdalta 13.12.2018, jolloin Suomessa vallitsi korkeapaine ja heikko tuuli. Tällainen synoptinen tilanne on otollinen inversion synnylle (Hyrkkänen et al., 2015), lisäksi inversio esiintyy tällöin yleensä laajalla alueella, mikä nähdään myös tässä esimerkkitalanteessa vertaamalla ECMWF:n ennustamaa lämpötilakenttää havaittuun lämpötilakenttään. Kuvassa 2.8 vasemman puoleinen lämpötilaennustekenttä vastaa edellä esitetyn emagrammin vaaleamman punaista sävyä, eli ECMWF:n 12-malliajon lämpötilaennustetta ajanhetkelle 13.12.2018 kello 00 UTC. Oikealla on piirretty havaittu lämpötilakenttä ennustetta vastaavalle ajanhetkelle, mikä on sama kuin edellä esitetyn emagrammin sininen käyrä. Sinisellä kolmiolla on kuviin merkitty Sodankylän läheinen paikka, josta kuvassa 2.7 näkyvä luotaus on tehty. Nähdään, että oikean puoleisessa kuvassa värisävyt ovat Lapissa melko laajalla alueella tummempia eli kylmempiä kuin vasemman puoleisessa kuvassa. Näillä alueilla lämpötilan ennustevirheet ovat suhteellisen suuria, kuten esimerkiksi Itä-Lapissa, missä ennusteen ja havainnon välillä voi kuvaa katsomalla löytää yli kymmenen celsiusasteen lämpötilan ennustevirheitä.



Kuva 2.8: Vasemmalla on ECMWF:n 12.12.2018 12 UTC malliajon ennustama lämpötilakenttä ajanhetkelle 13.12.2018 kello 00 UTC ja oikealla havaintokenttä piirrettynä ennustetta vastaavalle ajanhetkelle. Lämpötilakenttä on esitetty sekä isoviivoin että väriskaalalla siten, että mitä tummemman sininen väri on, sitä kylmemmät ovat lämpötilat. Harmaassa laatikossa on ilmoitettu isoviivaa vastaava lämpötila. Kuvaa on merkitty sinisellä kolmiolla Sodankylä, josta kuvassa 2.7 näkyvä luotaus on tehty. Nähdään, että lämpötilan yliennustevirhe esiintyy melko laajalla alueella, ja että ennustevirheen suuruus voi paikallisesti olla yli kymmenen astetta.

Talvisin Suomessa vallitsevista olosuhteista johtuen lämpötilan ennustevirheet eivät ole yleensä systemaattisia ja ne liittyvät lähes aina itse ilmiöön ja/tai siihen liittyvään fysiikkaan. Systemaattisia eli ajallisesti yhteneviä ennustevirheitä voidaan havaita esimerkiksi kesäisin sulkukorkeapainetilanteessa kun säämallit saattavat päivästä toiseen ennustaa päivän ylimpiä lämpötiloja kylmemmiksi kuin mitä ne todellisuudessa ovat. (Haiden et al., 2018). Kuvan 2.8 tapauksessa kyse on matalan kerroksen inversiosta ja kuvan 2.5 tapauksessa pilvisyydestä.

ECMWF:n inversiotilanteiden yliennustaminen on tunnettu ongelma (Hewson, 2019) ja se on syy siihen miksi tätä tutkimusta tehdään. Ilmatieteen laitos on raportoinut ongelmasta Euroopan keskipitkien sääennusteiden keskukselle vuotuisessa raportissaan. ECMWF on reagoinut ongelmaan tekemällä vuosina 2013-2014 joitakin muutoksia säämallin 2 metrin lämpötilakäsittelyyn. Muutos paransi ennusteita pohjoisessa, mutta heikensi niitä matalilla leveysasteilla, minkä vuoksi niitä ei otettu käyttöön (Haiden et al., 2014a).

3. Käytetty data ja aineisto

Tässä luvussa kerrotaan tarkemmin työssä käytetystä datasta ja aineistosta. Aliluvussa 3.1 kerrotaan tarkemmin kriteereistä, joiden perusteella havaintoasemajoukko on valittu. Aliluvussa 3.2 kerrotaan varsinaisesta ECMWF:n datasta ja luvussa 3.2.1 säteilymuuttujista hieman tarkemmin.

3.1 Valittu havaintoasemajoukko

Tätä tutkimusta varten on valittu Suomen havaintoasemia mahdollisimman kattavasti koko maasta, yhteensä 90 kappaletta. Asemia valittaessa on pyritty rajaamaan ulkopuolelle kaikki tunturiasemat, sillä näiltä asemilta saatavat tiedot esimerkiksi vallitsevasta tuulesta tai lämpötilasta ei ole yleistettävissä niiden koko ympäristöön asemien korkeuden vuoksi. Toiseksi asemajoukon on tarkoitus kuvata mantereisia olosuhteita, sillä vesistöillä - varsinkin merellä - on lämpötilan vaihteluita tasaava vaikutus. Näiden havaintoasemien tietoja käytetään lämpötilavirhettä arvioitaessa, joten ne muodostavat työssä käytetyn havaintoaineiston. Asemien tarkemmat tiedot löytyvät liitteestä A, jossa on kerrottu kustakin asemasta sen WMO-numero, nimi, korkeus merenpinnasta ja sijainti pituus- ja leveyspiirin avulla.

3.2 MOS-tietokannan ECMWF:n data

Työssä käytetty data on Ilmatieteen laitoksen oman MOS (Model Output Statistics)-tietokannan dataa, jonne on tallennettu havaintoasemapisteisiin interpoloituja ECMWF:n ennusteita jälkikäsitteilyä varten. Jälkikäsitteily voidaan suorittaa tilastollisin- ja koneoppimismenetelmin, jolloin varsinaisen säämallin fysiikan muokkaamisen sijaan MOS-mallia voidaan ”kouluttaa” havaintojen perusteella (Glahn and Lowry, 1972; Finnish Meteorological Institute, 2018). Ilmatieteen laitoksen MOS-tietokantaan on tallennettu kolmen tunnin aikaresoluutiolla joitakin pintasuureita ja suureita ylempää ilmakehää.

Jotta sääennuste saadaan havaintoasemapisteisiin, täytyy sääennustedata viedä ECMWF:n mallihilasta näille havaintoasemille. Havaintoasemapisteet useimmiten sijait-

sevat satunnaisesti, eikä säämallin hilapiste ja asemapiste todennäköisemmin sijaitse samassa kohtaa. Ilmatieteen laitoksella MOS-tietokannan datan tapauksessa ennuste asemapisteisiin viedään säämallin lähimmästä hilapisteestä.

Tähän työhön on valittu dataa talvikuukausilta (joulukuu-helmikuu) vuosilta 2013-2017, ja ennustepituuksilta 3-48 tuntia. MOS-dataa ja ennustepituuksia käytetään kahteen vuorokauteen asti, jotta tilastoitua dataa olisi käytössä mahdollisimman paljon. Nimittäin kuvan 2.3 perusteella nettoauringonsäteilyn ollessa nolla ja vuorokausivaihtelun puuttuessa voidaan olettaa, että virhe ei liity vuorokauden aikaan. Lisäksi työhön on valittu useita mallimuuttujia niin pinnalta kuin ylempää ilmakehästä. Jotkin mallista suoraan tulevat muuttujat eivät kuitenkaan sellaisenaan ole kovin informatiivisia, minkä takia osa muuttujista on muutettu ymmärrettävämpään muotoon seuraavien yhtälöiden avulla.

Mallimuuttuja Φ eli geopotentiali muutetaan Z :ksi eli geopotentialikorkeudeksi

$$Z = \frac{\Phi}{g} \quad (3.1)$$

missä $g = 9.80665 \text{ m/s}^2$ on Maan putoamiskiihtyvyys (Holton and Hakim, 2013, s.85). Lämpötilat on muutettu Kelvineistä (K) celsiusasteiksi ($^{\circ}\text{C}$):

$$T [^{\circ}\text{C}] = T [K] - 273.15 \quad (3.2)$$

missä T on lämpötila. Paineyksikkö on muutettu pascaleista (Pa) hehtopascaleiksi (hPa) jakamalla 100:lla ja säteilysuureet on muutettu kuvaamaan tehoa per pinta-ala (W/m^2) jakamalla alkuperäinen mallimuuttuja ennustepituudella sekunneissa. Tuulen nopeus on säämallissa esitetty erikseen tuulen u - ja v -komponenteilla, joista saadaan pythagoraan lauseella kokonaistuuli eli tuulen varsinainen nopeus:

$$V = \sqrt{u^2 + v^2} \quad (3.3)$$

missä V kuvaa tuulen nopeutta yksikössä m/s . Tuulen pystynopeus on ilmoitettu säämallissa ω :lla, jonka yksikkönä on Pa/s . Olettamalla synoptinen mittakaava, jossa horisontaalinen pituusskaala on noin 1000 km, geostrofien virtaus ja hydrostaattinen tasapaino, voidaan ω muuttaa w :ksi ($p = 925hPa$) eli pystynopeudeksi yksikössä m/s yhtälöllä

$$w = -\frac{\omega}{\rho g} \quad (3.4)$$

missä ρ on ilman tiheys (oletus: $\rho_{925 hPa} \approx \rho_{1000 hPa}$) ja g Maan putoamiskiihtyvyys (Holton and Hakim, 2013, s. 85).

Koska oletettiin synoptinen mittakaava, approksimaatioiden tulee päteä. Geostrofisessa approksimaatiossa oletetaan painegradienttivoiman ja coriolisvoiman tasapainottavan toisensa, jolloin keskipakovoiman, kitkan ja maan pallogeometriaan liittyvien parametrien oletetaan olevan merkityksettömän pieniä (Holton and Hakim, 2013, s. 42–44).

Tämä approksimaatio toimii parhaiten korkeammilla leveysasteilla, jolloin Rossbyn luku eli Ro on tarpeeksi pieni:

$$Ro \equiv \frac{U}{f_0 L} = \frac{10 \text{ m/s}}{1 \cdot 10^{-4} \text{ 1/s} \cdot 1000 \cdot 10^3 \text{ m}} = 0.1 \quad (3.5)$$

missä U tarkoittaa horisontaalista nopeusskaalaa, f_0 coriolisparametrin suuruusluokkaa ja L horisontaalista pituusskaalaa. Laskuesimerkki on suoritettu keskileveysasteille. Huomataan, että $Ro \leq 0.1$, joten voidaan sanoa geostrofisen oletuksen olevan oikeutettu approksimaatio (Holton and Hakim, 2013, s. 44). Hydrostaattisen tasapainon oletuksella tarkoitetaan sitä, että ilmakehässä ei esiinny virtauksia, jolloin ilmapakettiin vaikuttava noste ja Maan putoamiskiihtyvyys tasapainottavat toisensa (Holton and Hakim, 2013, s.18). Tällainen approksimaatio on aina suurpiirteinen eikä kovin tarkka, mutta sen voidaan olettaa olevan riittävän hyvä korrelaatioita ja muuttujien välisiä suhteita tarkasteltaessa, jolloin tarkoista lukuarvoista ei olla kiinnostuneita. Näin ollen synoptisen mittakaavan oletus on oikeutettu tässä työssä.

Tässä työssä tutkitut mallimuuttujat yksikköineen ja korkeuksineen on koottu taulukkoon 3.1. Lämpötilahavainnot, joihin ECMWF:n ennustettua lämpötilaa verrataan, on saatu valituilta havaintoasemilta Ilmatieteen laitoksen ilmastotietokannasta.

Taulukko 3.1: Tutkimuksessa käytettävät mallimuuttujat, niiden yksiköt ja painepinnat tai korkeudet, joilta näitä mallimuuttujia on tutkimukseen saatavilla.

Mallimuuttuja	Yksikkö	Painepinnat/Korkeudet
Pinnan havaittavan lämmön vuo	$\frac{W}{m^2}$	
Pinnan latentin lämmön vuo	$\frac{W}{m^2}$	
Havaattu lämpötila	°C	
Merenpintapaine	hPa	
2 metrin kastepistelämpötila	°C	
Alapilvipeite	%	
Keskipilvipeite	%	
Yläpilvipeite	%	
Maanpintalämpötila	°C	
Pinnan nettoauringsäteily	$\frac{W}{m^2}$	
Pinnan nettolämpösäteily	$\frac{W}{m^2}$	
Rajakerroksen korkeus	m	
Geopotentialikorkeus Z	gpm	500 hPa, 950 hPa
Tuulen nopeus	$\frac{m}{s}$	10 m, 100 m
Lämpötila	°C	2 m, 950 hPa, 925 hPa, 850 hPa eli niin sanottu <i>ilmamassan lämpötila</i> .
Suhteellinen kosteus	%	950 hPa, 925 hPa, 850 hPa
Pystynopeus	$\frac{cm}{s}$	925 hPa

3.2.1 ECMWF:n merkkikäytäntö säteilymuuttujille

Työssä on mukana mallimuuttujia, joille ECMWF:n säämallin merkkisäännöt ovat erilaiset kuin tyypillinen meteorologinen tulkinta. ECMWF:n merkkisääntöjen mukaan kaikki pinnan ja ilmakehän väliset vuot ovat *positiivisia* voiden suuntautuessa *ilmakehästä pintaan*. Tuloksia tulkittaessa säteilymuuttujien merkki luetaan kuvista kuten ne siinä ovat ja tulkinta annetaan sen perusteella.

Havaittavan lämmön vuo kuvaa johtumiseen ja turbulenttiseen sekoittumiseen liittyvän lämmön siirtymistä pinnan ja ilmakehän välillä, poislukien lämpösäteily (Trenberth et al., 2009). Jos vuo on positiivinen havaittavaa lämpöä siirtyy meteorologisesti ajateltuna pinnasta ilmakehään, negatiivinen vuon arvo kertoo havaittavan lämmön siirtyvän ilmakehästä pintaan (Ritter, 2016). ECMWF:n merkkikäytännössä vuo on positiivinen sen suuntautuessa ilmakehästä pintaan, joten maanpinnan jäähtyessä ja havaitun lämmön siirtyessä ilmakehään vuon merkki on tässä työssä merkkisäännöt huomioiden negatiivinen. Latentin lämmön vuo eli haihtumiseen ja tiivistymiseen liittyvän lämmön siirto noudattaa samoja merkkisääntöjä kuin havaittavan lämmön vuo (ECMWF, 2019).

Pinnan nettoauringonsäteily on meteorologisesti samansuuntainen kuin ECMWF:n merkkisääntöjen mukaan: maanpinnan saadessa nettomääräisesti auringonsäteilyä vuo on positiivinen (AMS Glossary, 2012).

4. Käytetyt menetelmät

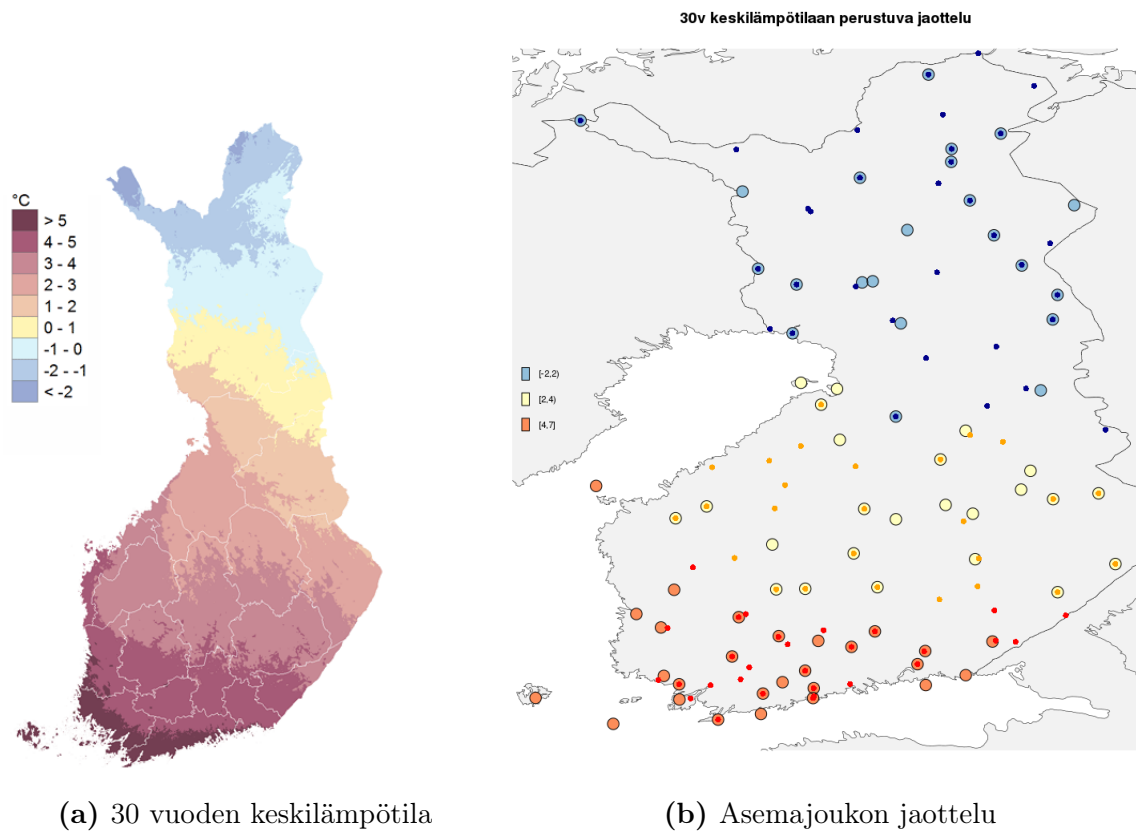
Tässä luvussa kerrotaan datan ja aineiston käsittelemiseen käytetyistä menetelmistä ja syistä, miksi kyseiset valinnat on tehty. Aliluvussa 4.1 kerrotaan asemajoukon jaottelusta kolmeen alueeseen sekä jaottelun perusteista. Aliluvussa 4.2 kerrotaan lämpötilan ennustevirheen luokkajaottelusta ja aliluvussa 4.3 työssä käytetyistä data-analyysimenetelmistä.

4.1 Havaintoasemajoukon jaottelu

Suomen maantieteellisen sijainnin sekä meren ja mantereen jakauman takia olosuhteet maan etelä- ja pohjoisosan välillä voivat olla hyvinkin vaihtelevat. Näin ollen tutkimuksen kannalta on hyödyllistä jakaa valitut asemat asemajoukkoihin jonkin asemajoukolle tyypillisen ilmastoa kuvaavan suureen perusteella. Asemien jakamisen perusteena käytetään tässä työssä Ilmatieteen laitoksen tilastoimaa 30 vuoden keskilämpötilaa, joka on esitetty kuvassa 4.1(a). Tilasto kattaa ajanjakson vuosilta 1981-2010.

Havaintoasemat jaetaan kolmeen eri alueeseen keskilämpötilan mukaan niin, että kullakin alueella on suurin piirtein yhtä suuri määrä ympäristöään edustavia asemia. Kuvaan 4.1 on piirretty kaikki 90 havaintoasemaa pienemmillä ympyröillä ja suuremmilla ympyröillä ne asemat, joille löytyy 30 vuoden lämpötilatilasto. Värikoodaus jakaa asemajoukon kolmeen osaan 30 vuoden keskilämpötilatilastoon perustuen: punainen - keskilämpötila välillä $[4, 7]$ °C, keltainen - keskilämpötila välillä $[2, 4]$ °C ja sininen - keskilämpötila välillä $[-2, 2]$ °C. Siniseen asemajoukkoon kuuluu yhteensä 33, keltaiseen 28 ja punaiseen 29 havaintoasemaa.

Liitteessä A on esitetty jokaisen tähän työhön valitun havaintoaseman tiedot aluekohtaisesti: WMO-numero, nimi, korkeus, pituuspiiri ja leveyspiiri. Tästä eteenpäin tiettyyn asemajoukkoon viitataan kuitenkin yksinkertaisuuden vuoksi alueeseen viittaavalla nimellä ”pohjoisen asemat”, ”keskiosan asemat” ja ”eteläosan asemat”, vaikka jaottelu perustuukin 30 vuoden keskilämpötilaan eikä maantieteelliseen jaotteluun. Joissain kuvissa voi esiintyä termit ”pohjoisosa”, ”keskiosa” tai ”eteläosa”, joilla myös tarkoitetaan näitä keskilämpötilan perusteella jaoteltuja asemajoukkoja.



Kuva 4.1: Vasemmalla on Ilmatieteen laitoksen tilastoima 30 vuoden keskilämpötila (1981 - 2010) ja oikealla asemajoukon jaottelu 30 vuoden keskilämpötilaan perustuen. Pienet pallot kuvaavat valittuja havaintoasemia, suuremmat pallot niitä havaintoasemia, joille löytyi 30 vuoden lämpötilatilasto. Eri värit jakavat asemat kolmeen eri alueeseen. Punaisella on merkitty ne asemat, joilla 30 vuoden keskilämpötila oli välillä $[4, 7]$ °C, keltaisessa välillä $[2, 4]$ °C ja sinisessä välillä $[-2, 2]$ °C. Siniseen asemajoukkoon kuuluu yhteensä 33, keltaiseen 28 ja punaiseen 29 havaintoasemaa.

4.2 Lämpötilan ennustevirheen jakaminen luokkiin

Data jaetaan viiteen eri luokkaan lämpötilan ennustevirheen mukaan, jotta pystytään vertailemaan eri parametrien jakaumia eri ennustevirheille. Luokkajaon rajat on määriteltä siten, että yksi luokka kattaa melko pienet ennustevirheet nollan ympärillä, missä arvoja on eniten ja kaksi luokkaa kuvaa lämpötilan ennustevirheen ääripäitä. Loput kaksi luokkaa sijoittuu näiden välille. Luokkajako on esitetty taulukossa 4.1. Taulukosta nähdään, että lämpötilan ennustevirheen ollessa välillä ± 5 celsiusastetta kuuluu ennuste luokkaan 3. Tämä luokka kattaa kuvan 2.3 histogrammin pienimmät lämpötilan yli- ja aliennustevirheet läheltä nollaa. Koska näistä virheistä ei olla tässä työssä kiinnostuneita, pidetään ne “hyvin ennustettuina”. Jos lämpötilavirhe on välillä 5...10 astetta, ennuste sijoittuu luokkaan 2. Vastaavasti lämpötilan ennustevirheen ollessa välillä -10...-5 luokka on 4. Luokat 1 ja 5 sisältävät kuvan 2.3 äärevimmät lämpötilan ennustevirheet, jolloin virheen suu-

ruus on itseisarvoisesti vähintään 10 astetta. Luokkien 1 ja 5 ylä- ja alarajaksi on valittu suurin lämpötilan yli- ja aliennustevirhe mitä datasta tutkitulla ajanjaksolta on löytynyt. Tarkat rajat lämpötilavirheen rajojen määrittelemiseksi on esitetty taulukossa 4.1. Huomataan myös, että luokan 3 lämpötilavirheen väli on 10 celsiusastetta, kun se muilla luokilla on yleisesti 5 celsiusastetta. Luokilla 1 ja 5 väli ei ole määritelty tarkasti, mutta näissä luokissa arvoja on huomattavasti vähemmän kuin luokassa 3.

Taulukko 4.1: Havaintojen lukumäärä kussakin luokassa alueittain. Taulukkoon on myös merkitty mikä lämpötilavirheen väli kuvaa mitäkin luokkaa. Taulukosta nähdään, että eniten arvoja on luokassa kolme, jossa on suhteellisen pienet lämpötilan ennustevirheet. Vastaavasti suuret lämpötilan ennustevirheet liittyvät useimmiten yliennustevirheisiin, sillä luokassa 1 on enemmän arvoja kuin luokassa 5. Pohjoisessa suuria yli- tai aliennustevirheitä on myös enemmän kuin muualla, mitä osittain selittää se, että pohjoisessa on myös enemmän ennusteita ja dataa saatavilla kuin muissa alueissa.

Luokka	Lämpötilavirheen väli ($^{\circ}\text{C}$)	Eteläosa	Keskiosa	Pohjoisosa
1]10, 22.15]	177	624	6 264
2]5, 10]	4 161	6 821	20 581
3]−5, 5]	189 705	179 880	192 713
4]−10, −5]	1 695	1 598	3 044
5]−16.35, −10]	20	13	66
Yht.]−16.35, 22.15]	199 242	192 304	226 640

Taulukkoon 4.1 on merkitty kuinka monta havaintoa kussakin luokassa alueittain on. Taulukosta huomataan sama kuin luvussa 2 on empiirisesti todettu: lämpötilan yliennustustilanteita on huomattavasti enemmän ja ne ovat siten todennäköisempiä kuin aliennustamistapaukset. Kuvan 2.3 histogrammista nähtiin myös, että eniten arvoja sijoittuu alueelle, jossa lämpötilan ennustevirhe on pientä. Tätä havaintoa vastaa luokka numero 3. Taulukkoa 4.1 tarkastellessa on hyvä huomata, että etelä-, keski- ja pohjoisosassa on eri määrä ennusteita ja siten saatavilla olevaa dataa. Luvut eivät siten ole vertailukelpoisia keskenään. Arvoja erityisesti luokissa 2, 3, ja 4 on kuitenkin pääasiassa niin paljon, että näillä eroilla ei pitäisi olla suurta merkitystä tulosten kannalta. Erityisesti luokan 5 kohdalla pieni otoskoko vaikuttaa tulosten tulkintaan ja niiden luotettavuuteen.

Kun tarkastellaan jokaista aluetta erikseen ja tutkitaan millaisia ennustevirheitä kultakin alueelta löytyy datan kattavalla ajanjaksolla, saadaan taulukko 4.2. Taulukosta huomataan, että pohjoisosassa tapahtuu suuremmat yli- ja aliennustevirheet. Taulukon lukuja tarkastelemalla huomataan myös, että kullakin alueella lämpötilan yliennustevirhe on ollut itseisarvoisesti suurempi kuin vastaava lämpötilan aliennustevirhe, mikä myös tukee kappaleessa 2 tehtyjä empiirisiä havaintoja.

Taulukko 4.2: Suurimmat lämpötilan yli- ja aliennustevirheet alueittain

	Eteläosa (° C)	Keskiosa (° C)	Pohjoisosa (° C)
Suurin lämpötilan aliennustevirhe	-15.75	-11.65	-16.35
Suurin lämpötilan yliennustevirhe	16.15	17.05	22.15

4.3 Data-analyysimenetelmät

Työssä halutaan selvittää ECMWF:n mallimuuttujien yhteyttä suuriin ennustevirheisiin ja löytää näiden välisiä riippuvuuksia. Tätä varten mallimuuttujien välisiä riippuvuuksia tutkitaan lineaarisen korrelaation avulla.

Lineaarinen korrelaatio kertoo muuttujien välisestä lineaarisesta riippuvuudesta, mutta sen perusteella ei voida tehdä päätelmiä syy-seuraussuhteista eli kausaalisuudesta (Kelleher, 2016). Havaitun korrelaation voi aiheuttaa jokin muu tekijä, jolla on yhteys molempiin muuttujiin (Kelleher, 2016). Esimerkiksi jos positiivisessa korrelaatiossa havaitaan kuvitteellisella muuttujalla a keskimääräistä suurempi arvo, havaitaan sellainen usein myös muuttujalla b (Kelleher, 2016; Laerd Statistics, 2018). Esitetyissä korrelaatiokuvissa käytetään lukujen sijasta väriskaalaa, jossa punainen väri kuvaa positiivista, sininen negatiivista korrelaatiota. Korrelaatiokertoimen ollessa lähellä ± 1 korrelaatio on vahvaa. Työssä on käytetty Pearsonin korrelaatiota ja pythonissa saatavilla olevaa *heatmap*-funktioita, jonka avulla korrelaatiokuvat on tehty.

Työssä halutaan tutkia voidaanko mallimuuttujien avulla erotella erilaisiin ennustevirheisiin liittyviä tilanteita. Tätä tutkittiin piirtämällä tiheysfunktioita, joista nähdään mallimuuttujan jakauma eri ennustevirheen suuruuksilla. Tiheysfunktioissa yksittäisen jakauman sovittamiseen on käytetty ydinestimointimenetelmää (eng. Kernel Density Estimation, KDE), jossa jokaisen yksittäisen jakauman määrittämiseen on käytetty silmämääräistä tarkastelua oikean ytimen leveyden määrittämiseksi. Liian pieni ytimen leveys tuo liian paljon yksittäisten maksimien tai minimien piirteitä esille, liian suuri toisaalta siloittaa liikaa tärkeitä piirteitä pois ja levittää jakaumaa liian paljon todellisen jakauman rajojen ulkopuolelle (Breheny, 2010). Silmämääräisellä tarkastelulla reuna-alueilla tapahtuva liian suuri jakauman levittäminen on voitu ottaa huomioon ja epäfysikaalisten tilanteiden esiintyminen on voitu tällä keinolla välttää. Tällöin esimerkiksi pilvisyyden tai suhteellisen kosteuden jakauma ei voi saada arvoja alle 0 tai yli 100 prosentin.

5. Mallimuuttujien välinen lineaarinen korrelaatio ja jakaumat lämpötilan ennustevirheen suhteen

Tässä luvussa käsitellään työssä tehdyn data-analyysin tulokset. Aliluvussa 5.1 tutkitaan mallimuuttujien välisiä korrelaatiota, joiden perusteella valitaan merkittävimmät mallimuuttujat tarkempaa analyysia varten. Tarkemmasta tiheysfunktioanalyysistä kerrotaan aliluvussa 5.2. Lopuksi aliluvussa 5.2.1 perehdytään tarkemmin inversion muodostumiselle otollisiin olosuhteisiin ja tutkitaan lyhyesti millainen on oleellisimpien mallimuuttujien jakauma lämpötilan ennustevirheen suhteen tällaisissa tapauksissa.

5.1 Mallimuuttujien ja lämpötilavirheen välinen lineaarinen korrelaatio

Kun tarkastellaan MOS-tietokannassa saatavilla olevien ECMWF:n mallimuuttujien välisiä lineaarisia korrelaatioita saadaan kolme korrelaatiomatriisia - yksi kullekin alueelle. Kuvassa 5.1 on nämä kolme korrelaatiomatriisia allekkain siten, että ylimpänä on pohjoisosan, keskimmäisenä keskiosan ja alimpana eteläosan havaintoasemajoukon mallimuuttujien väliset korrelaatiot. Kuvissa x- ja y-akseleilla on samat muuttujat. Muuttujien välinen korrelaatio on piirretty väriskaalalla ja väriä vastaavan korrelaation voi lukea väripalkista - punainen väri tarkoittaa positiivista, sininen negatiivista korrelaatiota. Mitä tummempi väri on, sitä voimakkaampi korrelaatio on. Kuvissa diagonaali kuvaa kunkin muuttujan välistä korrelaatiota itsensä kanssa, mikä on aina $+1$. Tässä tarkastellaan vain mahdollisia lineaarisia riippuvuuksia, eikä muita riippuvuuksia oteta huomioon.

Kuvasta 5.1 nähdään, että esimerkiksi kastepistelämpötilan ja havaitun lämpötilan välillä on voimakas positiivinen korrelaatio. Käytännössä tämä tarkoittaa, että kastepistelämpötilan tai kahden metrin lämpötilan nousua seuraa usein toisen kasvaminen, mikä käy järkeen. Tavoitteena on verrata T-ennustevirhe ($T_{ennustettu\ 2m} - T_{havaittu\ 2m}$) riviä muihin mallimuuttujiin ja löytää ne mallimuuttujat, joiden korrelaatio lämpötilavirheeseen eli

T-ennustevirheeseen olisi mahdollisimman suuri. Tämän tavoitteen helpottamiseksi taulukkoon 5.1 on merkitty lämpötilan ennustevirheen ja korrelaatiomatriisissa esitettyjen mallimuuttujien välinen korrelaatiokerroin kullekin tarkasteltavalle alueelle. Taulukosta ja korrelaatiomatriiseista nähdään, että kaiken kaikkiaan mallimuuttujien välinen lineaarinen korrelaatio lämpötilan ennustevirheen suhteen on heikkoa, mutta joitakin mielenkiintoisia piirteitä kuvista kuitenkin löytyy.

Havaittavan lämmön vuon korrelaatio lämpötilavirheen kanssa on lievästi negatiivinen ollen voimakkaampi etelässä kuin pohjoisessa. Tämä tarkoittaa sitä, että havaitun lämmön vuon ollessa negatiivinen (ECMWF: vuo pinnasta ilmakehään) säämalli tyypillisesti yliennustaa kahden metrin lämpötilaa. Latentin lämmön eli haihtumiseen ja tiivistymiseen liittyvän lämmön siirron tapauksessa korrelaatiot ovat hyvin heikkoja eivätkä siten merkittäviä.

Havaitun lämpötilan ja lämpötilan ennustevirheen välillä vallitsee negatiivinen korrelaatio, joka on voimakkaampi pohjoisessa kuin etelässä. Havaitun lämpötilan ollessa kylmä, lämpötilat ovat todennäköisemmin yliennustettuja, mikä on odotettu tulos. Merenpintapaineella ja kastepistelämpötilalla on molemmilla heikot, mutta vastakkaismerkkiset korrelaatiot lämpötilan ennustevirheen kanssa: pintapaineella positiivinen ja kastepistelämpötilalla negatiivinen. Merenpintapaineen ollessa korkea säämallilla on suurempi riski yliennustaa lämpötiloja. Vastaavasti kastepistelämpötilan ollessa korkea lämpötilat ovat helpommin aliennustettuja. Pintalämpötilan korrelaatio lämpötilan ennustevirheen välillä on samansuuntainen kuin kastepistelämpötilalla eli lievästi negatiivinen. Negatiivinen korrelaatio on hieman voimakkaampi pohjoisessa kuin etelässä, mutta kaiken kaikkiaan korrelaatio on silti heikkoa.

Ala-, keski- ja yläpilvillä on hyvin heikko korrelaatio lämpötilan ennustevirheen kanssa, mikä kuvastaa tässä tapauksessa enemmänkin sitä, että säämallin ennustama pilvisyys ei välttämättä ole ennustettu kovin hyvin. Alapilvillä on pohjoisessa lievästi negatiivinen, etelässä ja keskiosassa heikosti positiivinen korrelaatio.

Pinnalle saapuva nettoauringonsäteily on käytetyn datan tapauksessa hyvin pientä, kuten todettiin kappaleessa 2.2.1, joten lineaarinen korrelaatiokin on lähellä nollaa.

Alailmakehän stabiilisuuutta kuvaavan rajakerroksen korkeuden ja lämpötilan ennustevirheen välillä on negatiivinen korrelaatio, joka on voimakkaampi pohjoisessa ja hyvin heikkoa, käytännössä nolla etelässä. Ennustetun rajakerroksen korkeuden ollessa matala, lämpötilat ovat todennäköisemmin siis yliennustettuja. Tämä käy järkeen, sillä rajakerros on yleensä matala stabiileissa olosuhteissa (Mahrtand and Vickers, 2002) ja tällöin ECMWF:n kahden metrin lämpötilaennuste ei välttämättä ole kovin luotettava, kuten on luvussa 2.2 kerrottu.


950 hPa:n geopotentialikorkeudella ja lämpötilan ennustevirheen välillä on heikko positiivinen korrelaatio. Käytännössä tämä tarkoittaisi sitä, että mitä korkeampi 950

hPa:n geopotentialkorkeus, sitä suurempi lämpötilan yliennustaminen. Oletettavasti siis korkeapainetilanteessa on todennäköisempää yliennustaa lämpötiloja, mikä vaikuttaa järkevältä empiirisestä näkökulmasta.


Ilmamassan lämpötilalla ($T = 850hPa$) on hieman heikompi negatiivinen korrelaatio lämpötilan ennustevirheen kanssa kuin 950 hPa:n lämpötilalla. Säämallin ennustaman ilmamassan kylmentyessä myös kahden metrin lämpötilojen yliennustusriski kasvaa. Ilmamassan kylmentyessä myös pintalämpötilat kylmenevät, joten havainto tukee luvussa 2 tehtyjä empiiriä havaintoja.

Suhteellisten kosteuksien ja lämpötilan ennustevirheen väliset korrelaatiot ovat heikkoja pohjoisessa, muualla lähes nolla. Pohjoisessa korrelaatio on heikosti negatiivinen, eli mitä suuremmaksi ilman suhteellinen kosteus kasvaa, sitä enemmän lämpötilat ovat alienustettuja.


Kymmenen metrin tuulen nopeudella on hyvin heikko negatiivinen korrelaatio korrelaatiokertoimen ollessa lähes nolla. Heikolla tuulella lämpötilat voivat olla siten hieman yliennustettuja.



(a) maan pohjoisosan asemajoukko



(b) maan keskiosan asemajoukko



(c) maan eteläosan asemajoukko

Kuva 5.1: Mallimuuttujien välinen lineaarisen korrelaation korrelaatiomatriisi alueittain kuvattuna. Mitä punaisempi (sinisempi) väri, sitä positiivisempi (negatiivisempi) on kahden muuttujan välinen lineaarinen korrelaatio. Maan pohjoisosassa korrelaatiot ovat yleisesti suurempia kuin maan etelä- ja keskiosassa. Lämpötilan ennustevirheen kanssa mallimuuttujien korrelaatiot ovat yleisesti melko heikkoja

Taulukko 5.1: Mallimuttujen ja lämpötilan ennustevirheen välinen lineaarinen korrelaatiokerroin. Taulukosta nähdään, että korrelaatio on yleisesti heikkoa.

	hav. lämmön vuo	lat. lämmön vuo	havaittu T	pintapaine	kastepiste T	alapilvet	keskipilvet	yläpilvet	pinta T	nettoauringonsäteily	nettolämpösäteily	rajakerroksen kork.	Z_{950}	Z_{500}	w (p=925 hPa)	2 metrin T	ilmamassan T	T (p=950 hPa)	RH (p=950 hPa)	RH (p=925 hPa)	RH (p=850 hPa)	10 m tuulen nopeus
T-ennustevirhe pohjoisosa	-0.10	0.12	-0.68	0.19	-0.35	-0.10	-0.13	-0.15	-0.38	-0.07	-0.08	-0.28	0.17	-0.03	-0.04	-0.35	-0.26	-0.23	-0.20	-0.23	-0.16	-0.19
T-ennustevirhe keskiosa	-0.26	0.03	-0.55	0.19	-0.28	0.14	-0.01	-0.13	-0.30	-0.04	0.09	-0.12	0.17	-0.03	-0.02	-0.27	-0.31	-0.32	-0.05	-0.05	0.00	-0.19
T-ennustevirhe eteläosa	-0.23	-0.03	-0.48	0.16	-0.22	0.13	0.02	-0.07	-0.21	-0.03	0.08	-0.02	0.14	-0.02	-0.02	-0.19	-0.26	-0.28	0.03	0.02	0.02	-0.09

Taulukon 5.1 ja luvussa 2 tehtyjen empiiristen havaintojen perusteella tarkempaa tutkimusta eli tiheysfunktioanalyysia varten valitaan seuraavat mallimuuttujat: pintapaine, rajakerroksen korkeus, alapilvipeite, pintalämpötila, kastepistelämpötila, suhteellinen kosteus ($p = 925$ hPa), geopotentialikorkeus ($p = 500$ hPa ja $p = 950$ hPa), kymmenen metrin tuulen nopeus, lämpötila ($p = 950$ hPa ja $p = 850$ hPa), havaittavan lämmön vuo, latentin lämmön vuo ja nettolämpösäteily.

5.2 Mallimuuttujien jakaumat lämpötilan ennustevirheen suhteen

Aliluvussa 5.1 tehtyjen havaintojen perusteella tarkastellaan vain tiettyjä mallimuuttujia, joiden kanssa lämpötilan ennustevirhe korreloi lineaarisesti eniten. Tässä luvussa esitettävissä kuvissa on kaikissa sama pohja. Kuvan ylimmällä rivillä datana ja havaintoaineistona on käytetty pohjoista asemajoukkoa, keskirivillä maan keskiosan asemajoukkoa ja alimmalla rivillä eteläistä asemajoukkoa. Jokainen sarake kuvaa yhden mallimuuttujan vaihtelua alueittain. Käytetyt viisi lämpötilavirheluokkaa on merkitty jokaisessa yksittäisessä kuvassa eri väreillä siten, että säämallin yliennustevirheet on piirretty punaisen sävyillä ja aliennustevirheet sinisen sävyillä. Y-akseli kuvaa todennäköisyyttä. Todennäköisyyksien varsinaiset lukuarvot eivät tässä tarkastelussa ole niin mielenkiintoisia kuin todennäköisyyksien eroavaisuudet eri jakaumia kuvaavien käyrien välillä. Näin ollen yhdessä kuvassa on esitetty kolmen eri mallimuuttujan jakauma lämpötilan ennustevirheen suhteen kolmelle eri havaintoasemajoukolle. Kuvien mallimuuttujien jakaumien saamia lukuarvoja tarkastellessa pitää muistaa, että kyse on säämallin tuottamasta ennusteesta, ei havainnoista. Ideaalitulanteessa kuvissa esiintyvät jakaumat olisivat toisistaan täysin erillään: tätä tietoa voitaisiin käyttää ennustevirheen korjaamiseen jälkikäsitteilymenetelmin.

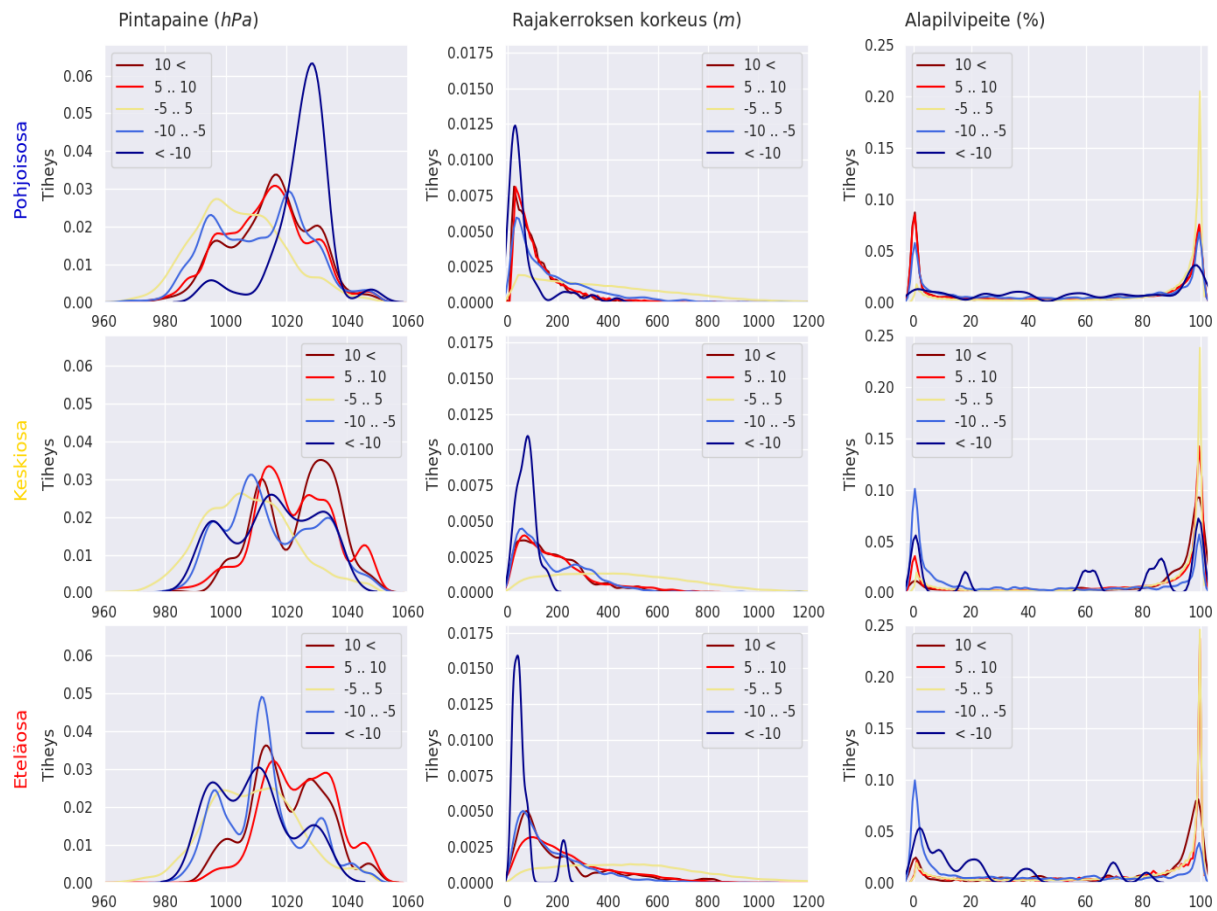
Tarkastellaan valituista muuttujista ensin pintapainetta, rajakerroksen korkeutta ja

alapilvisyyttä, jotka on esitetty kuvassa 5.2. Pintapaineen jakaumaa lämpötilan ennustevirheen suhteen tarkastellessa nähdään, että erot etelä- ja keskiosan jakaumissa verrattuna pohjoisosan jakaumiin ovat loppujen lopuksi melko pienet. Tilanteet, joissa säämalli on ollut huomattavasti liian kylmä ($< -10\text{ }^{\circ}\text{C}$ käyrä kuvassa) erottuu kyllä muista jakaumista, mutta taulukon 4.1 perusteella otoskoko kyseisen käyrän suhteen on jokaisella alueella hyvin pieni. Etelä- ja keskiosassa pienestä otoskoosta huolimatta tummansininen käyrä suhteutuu järkevällä tavalla vaaleansiniseen käyrään. Voidaan siten karkeasti päätellä lämpötilojen olevan todennäköisemmin aliennustettuja matalapaineen aikana ja yliennustettuja talvisen korkeapaineen aikana. Huomataan kuitenkin, että ECMWF:n säämallin taipuvaisuus yli- tai aliennustaa lämpötiloja näkyy pintapaineen kohdalla erityisen hyvin vasta piirrettyjen paineskaalojen reuna-alueilla. Pohjoisessa kaikki jakaumat ovat melkolailla toistensa kanssa päällekkäin, ja koska tumman sininen käyrä tällä alueella ei tue järkevästi vaaleansinisen käyrän jakaumaa, jätetään se huomiotta, sillä pienestä otoskoosta johtuen tämä jakauma voi olla vääristynyt. Pohjoisessa ei siis ole havaittavissa selkeää signaalia yli- tai aliennustevirheiden yhteydestä ennustettuun pintapaineeseen.

Rajakerroksen korkeutta tarkastellessa jakaumat näyttävät kaikilla kolmella alueella samanlaisilta: rajakerroksen korkeus on matala ennustevirheen laadusta huolimatta. Kuvissa tummansinisen aliennustevirhekäyrän jakauma erottuu kaikilla alueilla, mutta tästä käyrästä ei voida tehdä lopullisia johtopäätöksiä johtuen luokan pienestä otoskoosta. Tilanteissa, joissa lämpötilan ennustevirheet ovat olleet ± 5 astetta (keltainen käyrä) rajakerroksen korkeus on ollut tasaisemmin jakautunut kuin muissa ennustevirheen tapauksissa, ja korkeimmat ennustetut rajakerroksen arvot kuuluvat usein tähän luokkaan. Kaiken kaikkiaan rajakerroksen ennustetun korkeuden ollessa matala on vaikea sanoa minkälainen lämpötilan ennustevirheen suuruus on, sillä lähes jokaisella käyrällä on jonkinlainen todennäköisyysmaksimi samalla alueella. Rajakerroksen korkeusennusteen ollessa 100-400 metrin välillä kaikenlaiset lämpötilan ennustevirheet ovat yhtä todennäköisiä, mutta rajakerroksen korkeuden ollessa suurempi kuin 500 metriä lämpötilan ennustevirhe jää todennäköisemmin pieneksi.

Alapilvipeitteen jakaumia tarkastellessa huomataan, että jokaisella alueella on jonkinlainen todennäköisyysmaksimi nollan ja sadan prosentin kohdalla. ECMWF:n säämallille tämä on osittain tyypillistäkin, nimittäin ennusteissa pilvisiä ja täysin selkeitä tilanteita ennustetaan muita pilvisyyksiä todennäköisemmin (Haiden et al., 2015), mikä näkyy myös havainnoissa (Räisänen and Heino, 2008, s. 49–50). Yksikään käyrä ei erityisen hyvin erotu joukosta, mutta joitain eroavaisuuksia löytyy. Jokaisella alueella keltaisella käyrällä on muita käyriä suurempi todennäköisyysmaksimi sadassa prosentissa, mikä tarkoittaa että lämpötilavirheiden ollessa suhteellisen pieniä ennustettu pilvisuus on yleensä runsasta. Eteläosan kuvassa keltaisen kanssa erityisesti kirkkaan punainen väri menee huomattavissa määrin päällekkäin sadan prosentin kohdalla. Tämä johtuu siitä, että hyvin

usein pilvipeitteen äkillisestä repeämisestä seuraa talvella lämpötilojen nopea kylmeneminen maanpinnan kylmentyessä ulossäteilyn myötä ennustettua kylmemmäksi (NASA, 1999). Johtuen päällekkäisistä lämpötilan ennustevirheen jakaumista, alapilvisuysennusteen ollessa sata prosenttia ei voida sanoa onko lämpötilaennuste hyvä. Alapilvisuysennusteen ollessa lähellä nollaa prosenttia erityisesti maan etelä- ja keskiosan kuvissa korostuu lämpötilan aliennustevirheet. Näissä tilanteissa pilvisuus on todennäköisemmin ollut runsaampaa kuin ennustettu, jolloin maanpinnan ulossäteilystä johtuva kylmeneminen jää vähäisemmäksi. Alapilvipeitteen tapauksessa lämpötilavirheen käyrät menevät toistensa kanssa päällekkäin, joten erilaisten ennustevirheiden yhdistäminen ennustetun alapilvipeitteen runsauteen ei ole yksikäsitteisesti mahdollista.

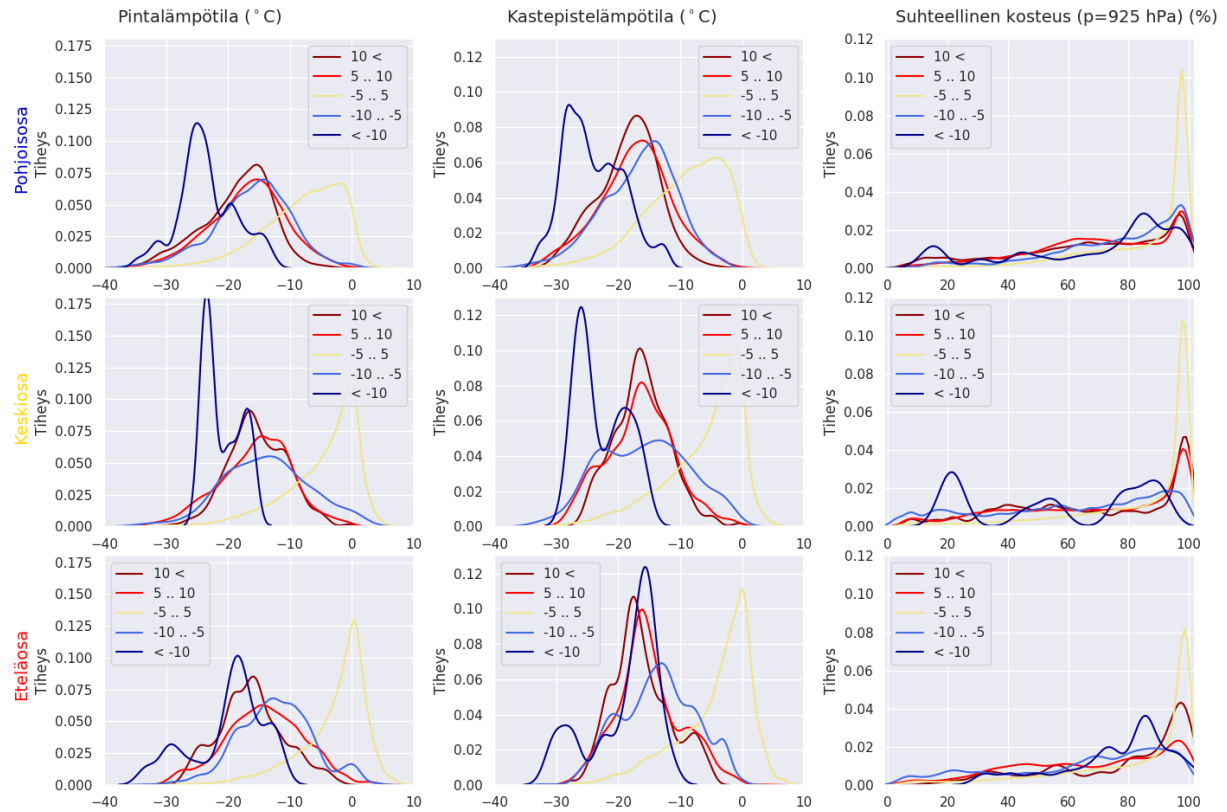


Kuva 5.2: Merenpintapaineen, rajakerroksen korkeuden ja alapilvipeitteen jakauma lämpötilavirheen suhteen alueittain etelän (alin rivi), keskiosan (keskirivi) ja pohjoisen (ylin rivi) havaintoasemajoukolle. Pintapaineen ollessa suuri lämpötilat ovat todennäköisemmin etelä- ja keskiosassa yliennustettuja ja vastaavasti aliennustettuja matalapaineen aikaan. Pohjoisessa selkeästi erottuva tummansininen käyrä jätetään huomiotta pienen otoskoon vuoksi. Kuvasta nähdään myös, että rajakerroksen korkeus on läpi talven melko matala, mutta sen ollessa muihin jakaumiin verrattuna keskimääräistä korkeampi, ennustevirheet jäävät todennäköisesti suhteellisen pieniksi. Alapilvipeitteen jakaumissa nähdään selvä jakaumien keskittyminen lähes nollaan ja lähes sataan prosenttiin. Pilvisuysennusteen ollessa lähempänä sataa prosenttia lämpötilaennusteiden osuvuus on yleisesti parempi.

Tarkastellaan seuraavaksi kuvaa 5.3, jossa on maanpintalämpötilan (kuvassa “pintalämpötila”), kahden metrin kastepistelämpötilan ja painepinta 925 hPa:n suhteellisen kosteuden jakaumat lämpötilavirheen suhteen. Huomataan että pintalämpötilan jakaumassa erottuvat selvästi pienet lämpötilan ennustevirheet keltaisella, sekä suuret lämpötilan aliennustevirheet tummansinisellä. Tummansiniset sävyt jätetään pienen otoskoon tarkastelun ulkopuolelle, sillä ne eivät tue millään alueella loogisesti vaaleansinisen käyrän jakaumaa. Maanpintalämpötilaennusteiden ollessa lähellä nollaa celsiusastetta kahden metrin lämpötilan ennustevirheet ovat tyypillisesti melko pieniä. Yliennustevirheet menevät kaikilla alueilla päällekin lievän aliennustamisen kanssa, eikä kumpiakaan tilanteita voida sitoa tietynlaisiin pintalämpötilaennusteisiin jakaumien perusteella.

Kahden metrin ennustettua kastepistelämpötilaa tarkastelemalla havaitaan jakaumien olevan hyvin samankaltaisia kuin pintalämpötilan tapauksessa: keltainen käyrä sijoittuu kuvissa lämpimiin kastepistelämpötilalukemiin ja tummansininen käyrä erottuu vaaleansinisestä käyrästä liian paljon erityisesti maan keski- ja pohjoisosassa pienen otoskoon vuoksi, jolloin se voidaan jättää huomiotta. Jokaisella alueella jakaumat ovat päällekkäin eikä ennustetun kastepistelämpötilan perusteella voida sanoa kovin paljoa lämpötilan ennustevirheen suuruudesta tai suunnasta. Kuitenkin ennustetun kastepistelämpötilan ollessa talvella suhteellisen korkea ($-10 \dots +5$ astetta), keltaisella käyrällä on maksimi ja lämpötilan ennustevirhe on todennäköisemmin pieni.

Kuvan 5.3 oikeassa sarakkeessa on suhteellinen kosteus painepinnalta $p = 925$ hPa. Alueilla kaiken kaikkiaan jakaumien suurimmat todennäköisyydet ovat sijoittuneet suurimpiin suhteellisiin kosteuksiin. Erityisesti ennustetuissa sadan prosentin suhteellisen kosteuden arvoissa ECMWF:n säämallin lämpötilan ennustevirheet ovat todennäköisemmin melko pienet. Vaikka pienillä suhteellisen kosteuden arvoilla lämpötilan aliennustevirheet (vaaleansininen) korostuvat hieman, menevät jakaumat kaikilla alueilla niin päällekkäin, että tilanteesta riippumatta lämpötilan ennustevirhe voi olla mitä vain.



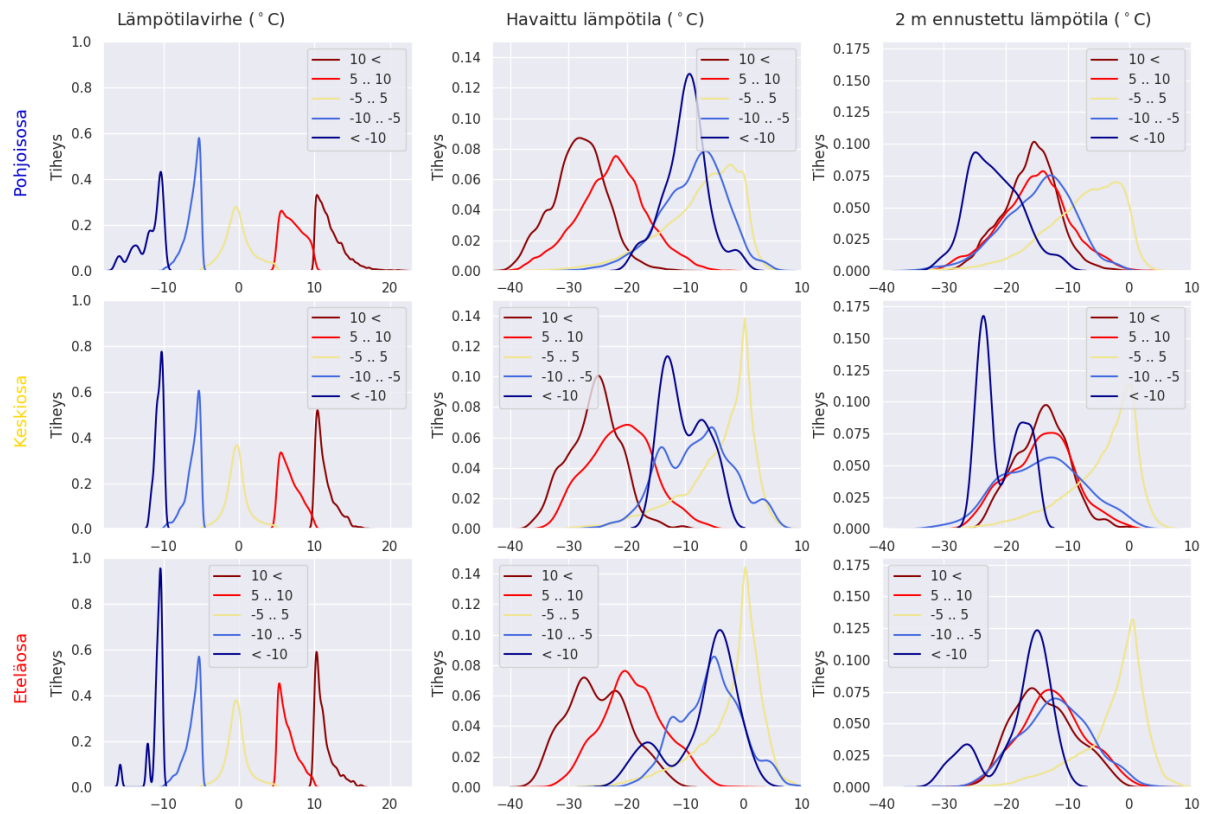
Kuva 5.3: Maanpintalämpötilan (kuvassa “pintalämpötila”), kahden metrin kastepistelämpötilan ja suhteellisen kosteuden ($p = 925$ hPa) jakaumat lämpötilan ennustevirheen suhteen. Ennustetun maanpintalämpötilan ja kastepistelämpötilan ollessa suhteellisen lämpimiä on todennäköistä, että kahden metrin lämpötilat ovat hyvin ennustettuja. Suhteellisen kosteuden jakaumissa ennustevirheen suhteen ei näy selkeää tilannetta, jolloin malli pyrkisi enemmän yli- tai aliennustamaan lämpötiloja, sillä jakaumien käyrät sijoittuvat pääasiassa päällekkäin.

Tarkastellaan seuraavaksi kuvaa 5.4, jossa on esitetty lämpötilavirheen, havaitun lämpötilan ja ennustetun kahden metrin lämpötilan jakaumat ennustevirheen suhteen. Kuvan ensimmäisessä sarakkeessa on lämpötilavirheen jakauma. Kuvat siis kertovat min-käläiset ovat kunkin lämpötilaennustevirheluokan todennäköisyydet ja millaisiin lämpötiloihin näiden luokkien suurimmat todennäköisyydet sijoittuvat. Melko helposti nähdään, että erityisesti pohjoisessa suurimmat virheet liittyvät lämpötilan yliennustustapauksiin, mikä tukee luvussa 2 tehtyjä havaintoja.

Havaitun lämpötilan jakaumista nähdään sama mikä on empiirisesti havaittu luvussa 2: lämpötilan ollessa hyvin kylmä (< -20 celsiusastetta) lämpötilojen yliennustamisen todennäköisyys kasvaa. Suurilla lämpötilan yliennustevirheillä (tumman punainen käyrä) on jokaisella alueella huippu havaitun lämpötilan ollessa $-25 \dots -30$ celsiusastetta. Syynä tähän voi olla esimerkiksi matalan inversion kehittyminen, lauhtumisen ajoittamiseen liittyvät vaikeudet tai pilvipeitteen odottamaton repeileminen (aliluku 2.2.1). Lämpötilan ollessa -5 ja -15 celsiusasteen välillä lämpötilojen kohtalainen tai huomattava aliennustaminen on todennäköistä, mutta koska kaikki jakaumat menevät päällekkäin, ei yksiselitteisesti voida

sanoa minkä suuruinen lämpötilan ennustevirhe tällaisessa tilanteessa on.

Kahden metrin ennustetun lämpötilan kohdalla havaitaan, että mitä lähempänä ennustetut lämpötilat ovat nollaa, sitä suuremmat ovat todennäköisyydet pieneksi jääville ennustevirheille. Tämä näkyy jokaisen alueen kuvassa keltaisella käyrällä. Lämpötilojen ollessa normaalin talviset (0...-20 celsiusastetta) jakaumat ovat toistensa päällä ja on vaikea sanoa millainen kahden metrin lämpötilaennusteen virheen suuruus tulee olemaan. Kahden metrin ennustetun lämpötilan tapauksessa tummansiniset käyrät voidaan jäättää ainakin osin huomioimatta pienen otoskoon aiheuttaman mahdollisen väärentymän myötä. Kuvasta nähdään, että ennustetun lämpötilan jakauma on huomattavasti kapeampi verrattuna havaitun lämpötilan jakaumaan. Esimerkiksi malliennusteet loppuvat jo -30 celsiusasteen paikkeilla, vaikka havainnoissa on vielä todennäköisyyksiä -40 °C:seen saakka.

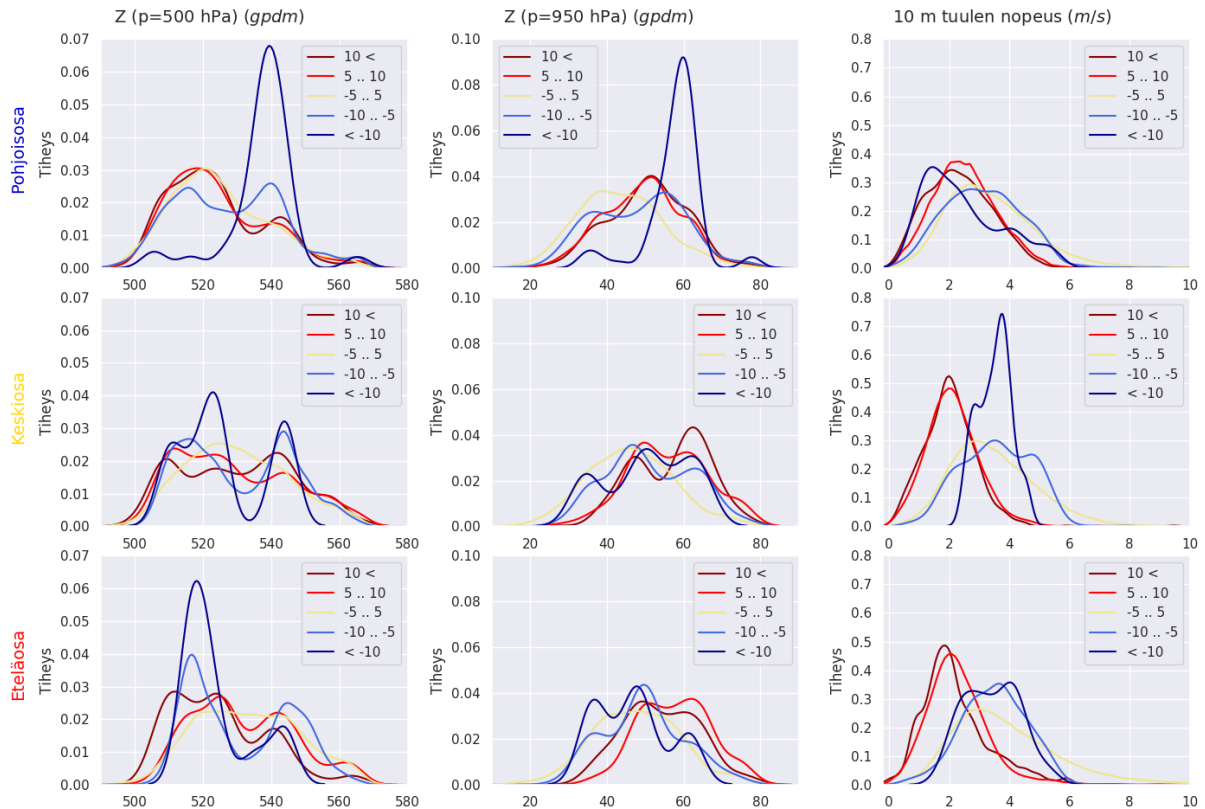


Kuva 5.4: Lämpötilavirheen jakaumat sekä havaitun lämpötilan ja kahden metrin ennustetun lämpötilan jakaumat lämpötilan ennustevirheen suhteen. Lämpötilavirheen jakaumista nähdään, että suurimmat lämpötilaennustevirheet tapahtuvat pohjoisessa. Havaituissa lämpötiloissa ennustevirheen suhteen nähdään jokaisen kuvan kohdalla kohtalaista tai suurta yliennustamista hyvin kylmissä lämpötiloissa. Vertaamalla havaittujen lämpötilojen jakaumia ennustettuihin lämpötilan jakaumiin nähdään, että ECMWF:n säämalli ei ennusta niin kylmiä lämpötilalukemia kuin mitä on havaittu. Vastaavasti suhteellisen lämpimissä olosuhteissa ennustevirheet jäävät todennäköisemmin pieniksi.

Kuvassa 5.5 on geopotentialkorkeus painepinnalta $p = 500$ hPa ja $p = 950$ hPa se-

kä kymmenen metrin tuulen nopeus. Geopotentialkorkeuksia tarkastellessa huomataan, että suuret aliennustustilanteet (tummansiniset käyrät) eivät sulaudu vaaleansinisiin käyriin maan pohjoisosassa odotetulla tavalla, vaan erottuvat niistä voimakkaasti johtuen pienestä otoskoosta. Nämä käyrät jätetään siten maan pohjoisosassa tuloksia tarkastellessa huomiotta. Maan eteläosassa pieniin geopotentialkorkeuksiin ylemmällä painepinnalla ($p = 500$ hPa) näyttäisi liittyvän hieman todennäköisemmin yliennustevirheitä, ja alemmalla painepinnalla ($p = 950$ hPa) aliennustevirheitä. Koska suuret geopotentialkorkeudet liittyvät usein myös suuriin paineen arvoihin (Holton and Hakim, 2013, s. 81–82), on alemman painepinnan geopotentialkorkeuden jakaumissa samoja piirteitä kuin pintapaineen jakaumissa. Paineen $p = 500$ hPa kuvia tarkastellessa nähdään, että hieman keskiarvoa suuremmilla geopotentialkorkeuden arvoilla ($Z = 540 - 550$ gpdm) kahden metrin lämpötilat ovat hieman todennäköisemmin aliennustettuja erityisesti maan keski- ja pohjoisosassa. Muuten käyrät ovat enimmäkseen päällekkäin eikä geopotentialkorkeus yksiselitteisesti kerro lämpötilan ennustevirheen suunnasta tai suuruudesta.

Kymmenen metrin tuulen nopeuden jakaumassa käyrät ovat muiden mallimuuttujien tapaan pääasiassa päällekkäin, mutta suuntaa siitä miten tuulen nopeus vaikuttaa lämpötilan ennustevirheen suuruuteen on kuitenkin nähtävissä. Kuvasta nähdään heti, että punaiset käyrät eli lämpötilan yliennustevirheet sijoittuvat erityisesti maan etelä- ja keskiosassa pienempiin ennustettuihin tuulen nopeuksiin kuin siniset. Tämä tarkoittaa sitä, että ECMWF:n ennustaessa talvella heikkotuulista säätä, ennustetut lämpötilat ovat todennäköisimmin yliennustettuja. Aliluvussa 2.2.1 todettiin, että talvella heikkotuulisissa tilanteissa matalan kerroksen inversion synnylle ja siten yliennustevirheille on otolliset olosuhteet, mikä saattaa osaltaan selittää tehtyä havaintoa. Maan pohjoisosassa aliennustevirheet eivät niinkään erotu muista lämpötilavirheen jakaumista, joten vastaavanlaista signaalia tuulen nopeuden vaikutuksesta lämpötilan ennustevirheeseen ei havaita. Maan etelä- ja keskiosassa erityisesti tilanteissa, joissa kymmenen metrin tuulen nopeus on ollut 0–2 m/s, yliennustamisvirheet ovat olleet todennäköisempiä. Kun lämpötilan ennustevirheet ovat olleet pieniä, kymmenen metrin tuulen nopeudet ovat olleet tyypillisesti hieman suurempia. Tämän seurauksena tuuli sekoittaa ilmaa ja purkaa siten pintainversion tai sitä ei pääse syntymään (Karttunen et al., 2008, s. 74).



Kuva 5.5: Geopotentialikorkeuden jakauma painepinnoilta $p = 500$ hPa, $p = 950$ hPa sekä 10 metrin tuulen nopeuden jakauma eri lämpötilan ennustevirheille. Geopotentialikorkeuden yksikköinä on geopotentialidekametri. Geopotentialikorkeuden kuvissa näkyy kuinka varsinkin maan etelä- ja keskiosassa alemman painepinnan ($p = 950$ hPa) matala geopotentialikorkeus liittyy todennäköisemmin aliennustamiseen ja ylemmällä painepinnalla ($p = 500$ hPa) yliennustamiseen. Pohjoisessa yhtä selkeää jakaumaa ei ole nähtävissä. Muut käyrät menevät toistensa kanssa pääasiassa päällekkäin. 10 metrin tuulen nopeuden jakaumassa erottuu lämpötilan yliennustevirheiden esiintyminen tilanteissa, joissa ennustettu tuulen nopeus on heikko. Suhteellisen voimakkailla tuulen nopeuksilla lämpötilan ennustevirheet ovat todennäköisimmin pieniä.

Jos tarkastellaan MOS-tietokannassa käytettävissä olevan ECMWF:n säämallin alimman painepinnan ($p = 950$ hPa) ennustettua lämpötilaa ja kahden metrin ennustettua lämpötilaa, saadaan karkea arvio siitä onko säämalli ennustanut inversiota kyseisen kerroksen välille vai ei. Jos näiden mallimuuttujien välinen erotus $T_{950} - T_{2m}$ on positiivinen niin lämpötila painepinnalla 950 hPa on korkeampi kuin kahden metrin lämpötila. Tällöin säämalli ennustaa inversiota, sillä lämpötila kasvaa korkeuden funktiona. Vastavasti erotuksen ollessa negatiivinen malli ei ennusta inversiota, vaan yleensä normaalia tilannetta. Tätä erotusta kutsutaan tästä eteenpäin nimellä *inversioluku*.

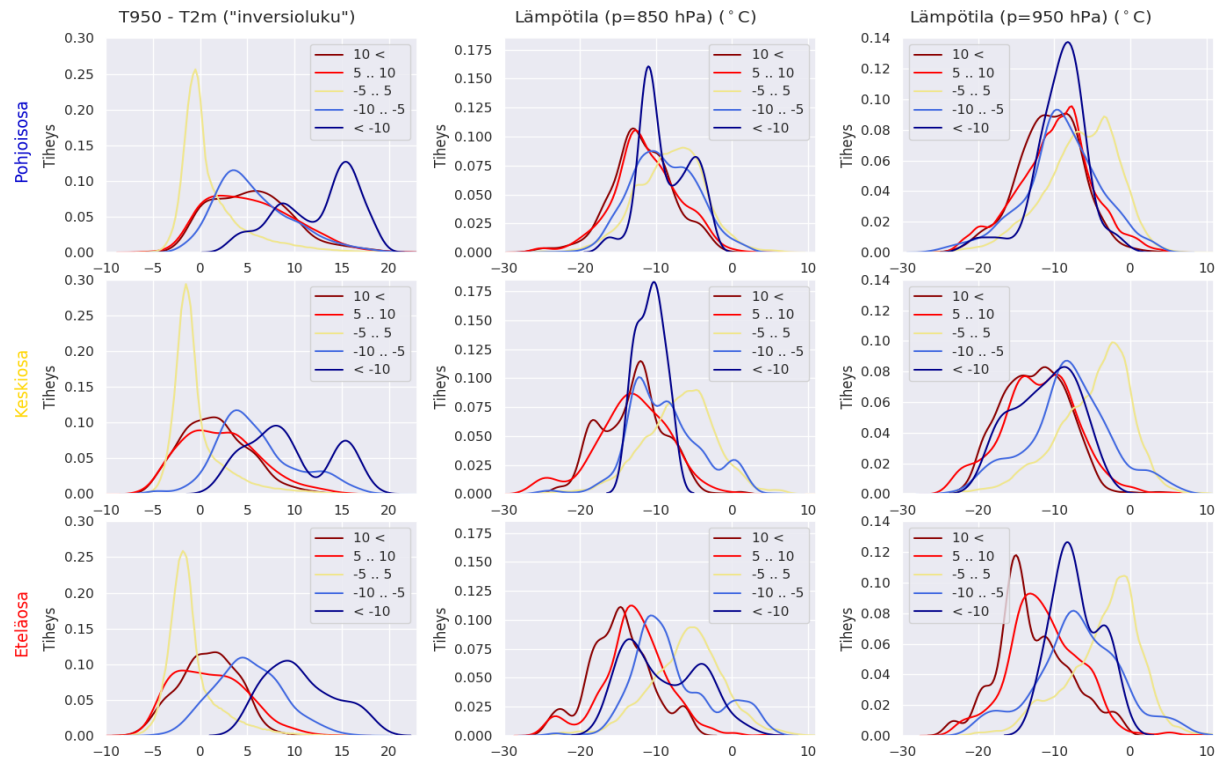
Kuvassa 5.6 on edellisten kuvien tapaan kolmen eri mallimuuttujan jakaumat lämpötilan ennustevirheen suhteen. Ensimmäisessä sarakkeessa on inversioluku ($T_{950} - T_{2m}$), toisessa ilmassan lämpötila eli painepinnan $p = 850$ hPa lämpötila ja kolmannessa sarakkeessa painepinnan $p = 950$ hPa lämpötila. Työssä käytetystä datasta piirrettynä (ei

näytetä) painepinta $p = 850$ hPa sijaitsee talvella keskimäärin noin 1000 metrin korkeudessa ja painepinta $p = 950$ hPa noin 400-600 metrin korkeudessa.

Inversioluvun ollessa nolla lämpötilan ennustevirheet ovat olleet suhteellisen pieniä. Vastaavasti säämallin ennustaessa suurta inversiota (inversioluku $\gg 0$) lämpötiloja tyypillisesti aliennustetaan. Eli mitä positiivisempi inversioluku on, sitä suuremmat ovat tyypillisesti lämpötilan aliennustevirheet. Kuvista nähdään myös, että säämallin yliennustaessa lämpötiloja (punaiset värit) pohjoisessa, ennustetun inversion voimakkuus on vain noin viisi astetta ja jakaumat ovat päällekkäin muiden käyrien kanssa, mikä voisi viitata siihen, että malli ei ennusta inversiota tarpeeksi voimakkaaksi. Yliennustevirheistä saatava informaatio ei ole siten täysin yksikäsitteistä.

Painepinnan $p = 850$ hPa lämpötilaa eli ilmamassan lämpötilaa tarkastellessa huomataan kuinka kaikilla alueilla jakaumat menevät pääasiassa päällekkäin, ja oleellista informaatiota saadaan vain lämpötilaskaalan "ääripäistä". Ilmamassan lämpötilan ollessa vähintään arktisen kylmää (≤ -18 celsiusastetta) lämpötilojen yliennustaminen (punaiset käyrät) on huomattavasti tyypillisempää. Vastaavasti talvella suhteellisen lämpimissä ilmamassoissa (0...-5 celsiusastetta) lämpötilat ovat joko aliennustettuja tai hyvin ennustettuja. Näiden ääripäiden välillä jakaumat ovat päällekkäin kaikilla alueilla ja lämpötilan ennustevirheen suuruus voi olla mitä vain.

Painepinnan $p = 950$ hPa lämpötilaa tarkastellessa huomataan kuinka erityisesti pohjoisessa jakaumat menevät täysin päällekkäin eikä kyseinen mallimuuttuja toimi erilaisten lämpötilan ennustevirhetilanteiden erotteluun tällä alueella. Maan keskiosassa ainoastaan ne tilanteet, joissa lämpötilan ennustevirheet ovat olleet pieniä, erottuvat jonkin verran muista jakaumien käyristä. Jos ennustettu lämpötila on ollut suhteellisen korkea painepinnalla $p = 950$ hPa, todennäköisintä on ennustevirheen jääminen pieneksi. Maan eteläosassa lauhojen lämpötilojen kohdalla käyrät ovat päällekkäin ja näissä tilanteissa on vaikea sanoa minkä suuruinen lämpötilan ennustevirhe tulee olemaan missäkin tilanteessa. Hyvin kylmien lämpötilojen tapauksessa etelässä lämpötilojen yliennustamisvirheet ovat todennäköisimpiä.



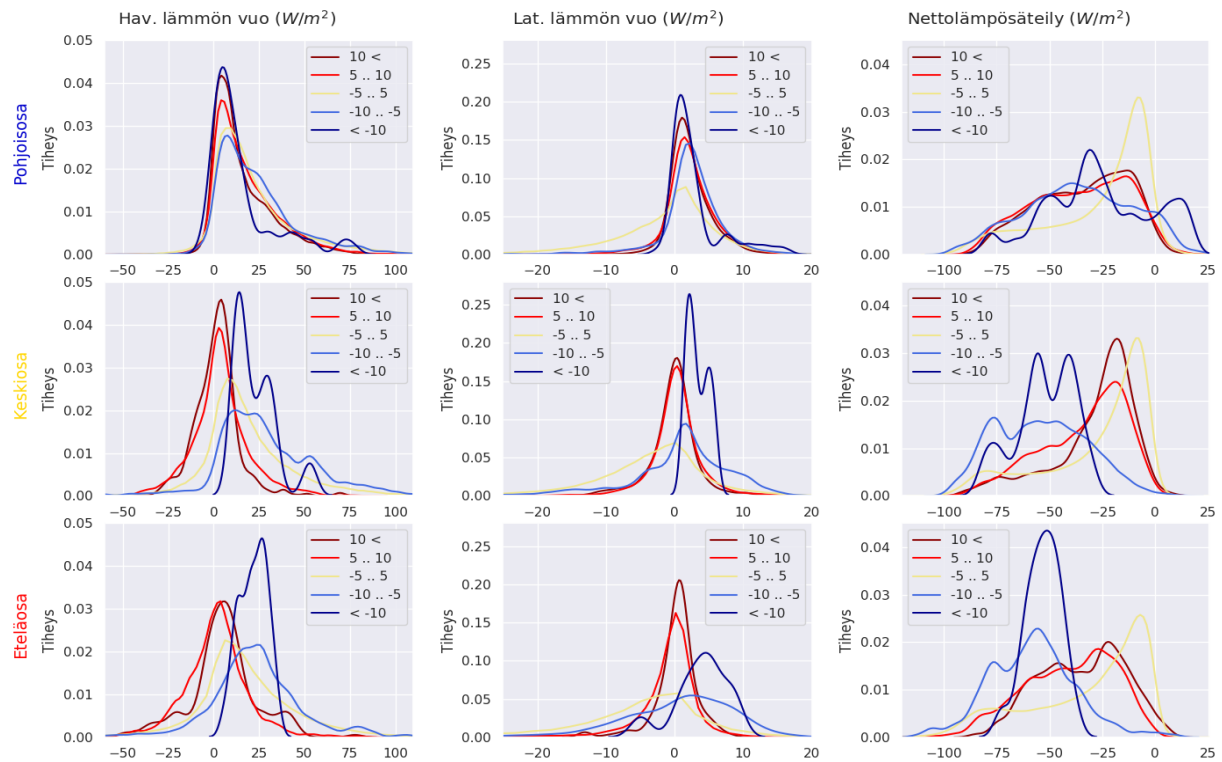
Kuva 5.6: Inversioluvun ($T_{950 \text{ hPa}} - T_{2m}$), ilmassan lämpötilan ($T = 850 \text{ hPa}$) ja painepinnan $p = 950 \text{ hPa}$ lämpötilan jakauma lämpötilan ennustevirheen suhteen. Jos säämalli ennustaa voimakasta inversiota (inversioluku suurempi kuin nolla), ennustetut lämpötilat ovat todennäköisimmin liian kylmiä eli malli aliennustaa. Ennustetun ilmassan lämpötilan (painepinta $p = 850 \text{ hPa}$) ollessa vähintään arktisen kylmä (≤ -18 celsiusastetta) lämpötilojen yliennustaminen on todennäköisempää. Painepinnan $p = 950 \text{ hPa}$ lämpötilojen kohdalla eroja jakaumissa nähdään pääasiassa maan etelä- ja keskiosassa. Näillä alueilla $p=950 \text{ hPa}$:n ennustetun lämpötilan ollessa suhteellisen lämmin, ennustevirhe on yleensä pieni tai säämalli aliennustaa lämpötiloja. Jos säämalli yliennustaa lämpötiloja niin painepinnan $p = 950 \text{ hPa}$ lämpötila on yleensä hyvin kylmä.

Tarkastellaan ilmakehän säteilyparametreja ja sitä miten niiden suuruus vertautuu lämpötilan ennustevirheeseen. Kuvassa 5.7 on havaitun ja latentin lämmön voien sekä nettolämpösäteilyn jakaumat lämpötilan ennustevirheen suhteen. Muistetaan luvusta 3.2.1, että ECMWF:n merkkisääntöjen mukaan vuon arvo on positiivinen jos se suuntautuu ilmakehästä maanpintaan. Kuvasta nähdään, että havaitun lämmön vuon ollessa nolla tai negatiivinen eli vuon suuntautuessa maasta ilmakehään, ECMWF:n säämalli todennäköisemmin yliennustaa lämpötiloja erityisesti maan etelä- ja keskiosassa. Jos ennustettu havaitun lämmön vuon on vain vähän positiivinen ($10\text{--}40 \text{ W/m}^2$), niin säämallin lämpötilat ovat todennäköisemmin aliennustettuja. Kyseisellä välillä myös muunlaiset lämpötilan ennustevirheet ovat kuitenkin mahdollisia. Maan pohjoisosassa selvää jakautumista eri virheluokkien välillä ei ole.

Latentin lämmön vuon kuvasta nähdään, kuinka vuon ollessa lähellä nollaa W/m^2 lämpötilojen yliennustaminen on todennäköisintä. Mitään varmaa yliennustamiseen liit-

tyen ei voida sanoa, sillä myös muut käyrät saavat jonkinlaisia todennäköisyyksiä samalla alueella. Maan etelä- ja keskiosassa lämpötilojen aliennustamisen todennäköisyys kasvaa latentin lämmön vuon ollessa yli 5 W/m^2 , jolloin vuo suuntautuu kohti maanpintaa. Pohjoisosassa vastaavanlaisia jakaumien eroavaisuuksia ei ole nähtävissä ja kaikki käyrät menevät täysin toistensa kanssa päällekkäin.

Pinnan ennustetun nettolämpösäteilyn ollessa negatiivinen maa menettää energiaa. Kuvasta nähdään, että nettolämpösäteilyn suuruus on jokaisella alueella negatiivinen, mikä käy järkeen auringosta tulevan säteilyn ollessa minimaalinen Suomessa talvisin. Jakaumat ovat kuitenkin jokaisella alueella varsinkin pohjoisessa niin päällekkäin toistensa kanssa, että minkäänlaista yleistä linjaa siitä millaisia lämpötilan ennustevirheitä kukin tilanne aiheuttaa ei ole. Maan etelä- ja keskiosan osilta voidaan karkeasti todeta, että mitä negatiivisempaa nettolämpösäteily on, sitä suuremmalla todennäköisyydellä ennustetut lämpötilat maan etelä- ja keskiosassa ovat liian kylmiä (siniset käyrät). Vastaavasti mitä lähempänä nollaa pinnan nettolämpösäteily on, sitä todennäköisemmin lämpötilat ovat hyvin ennustetut. Lämpötilojen ollessa yliennustettuja pinnan nettolämpösäteily on yleensä hieman negatiivinen.



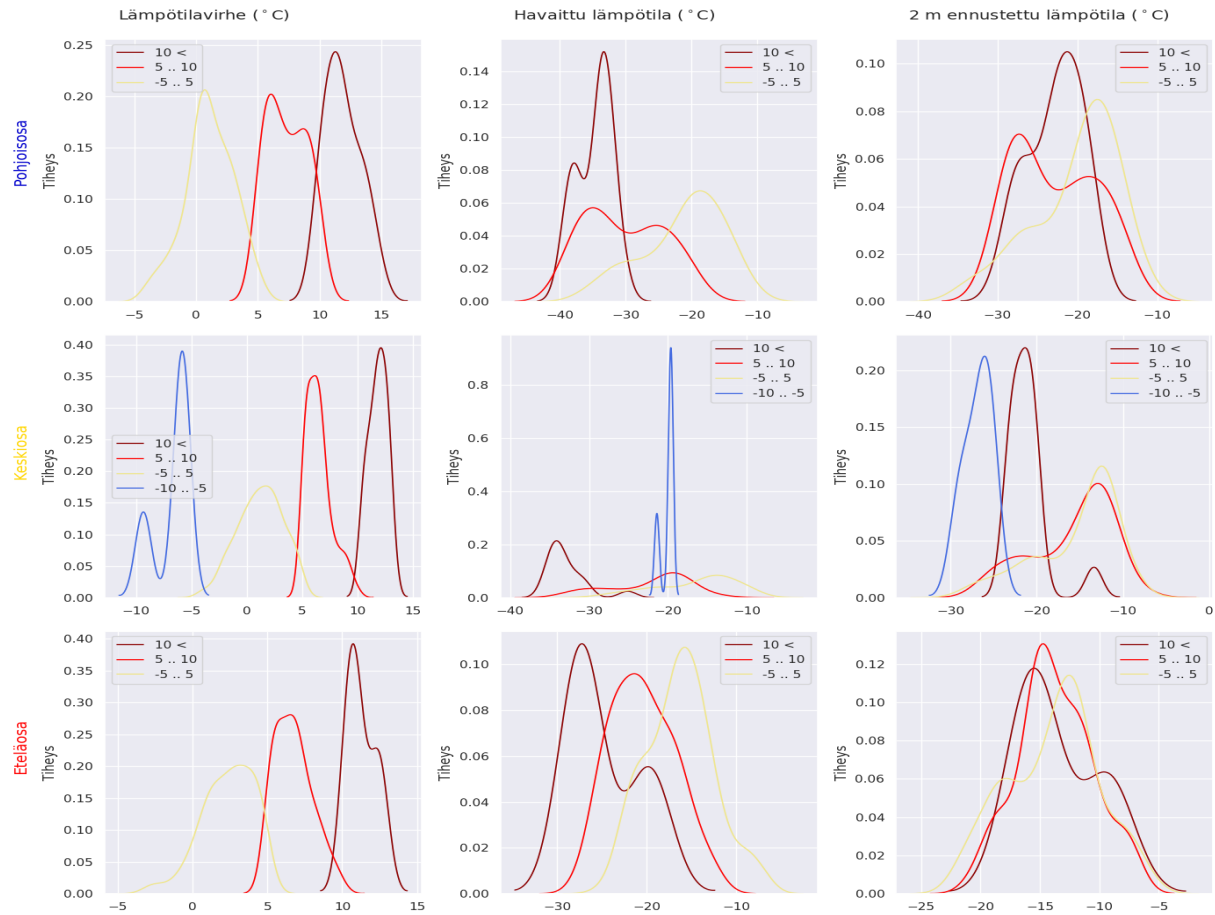
Kuva 5.7: Havaitun ja latentin lämmön voiden ja nettolämpösäteilyn jakauma ennustevirheen suhteen (ECMWF: vuo positiivinen kun suuntautuu ilmakehästä maanpintaan). Pohjoisessa kaikkien mallimuuttujien jakaumat menevät päällekkäin. Maan etelä- ja keskiosassa havaittavan ja latentin lämmön vuon ollessa lähellä nollaa tai negatiivinen eli vuon suuntautuessa pinnasta ilmakehään, lämpötilojen yliennustaminen on todennäköisempää. Nettolämpösäteilyn tapauksessa aliennustamista tapahtuu karkeasti ottaen enemmän mitä negatiivisempia arvoja mallimuuttuja saa.

5.2.1 Merkittävimpien mallimuuttujien jakauma lämpötilan ennustevirheen suhteen inversiolle suotuisissa olosuhteissa

Tässä aliluvussa tarkastellaan lyhyesti mallimuuttujien jakaumia lämpötilan ennustevirheen suhteen kun dataa rajataan lämpötilan yliennustamistilanteita silmälläpitäen, sillä yliennustamistilanteet eivät kovin hyvin erottuneet lämpötilan aliennustevirheistä edellisissä jakaumakuvissa. Rajataan data käyttämällä edellisessä aliluvussa tehtyjä havaintoja. Huomattiin, että pintapaineen, kymmenen metrin tuulen nopeuden, ilmassan lämpötilan ($p = 850$ hPa) ja havaittavan lämmön vuon kohdalla yliennustamistilanteet olivat muista jakaumista selvimmin erillään. Käytetään seuraavia rajausvaatimuksia: pintapaineen tulee olla suurempaa kuin 1020 hPa, tuulen nopeuden tulee olla pienempää kuin 3 m/s, ilmassan tulee olla kylmempää kuin -15 °C ja havaittavan lämmön vuon tulee olla alle 0 W/m^2 eli suuntautua pinnasta ilmakehään.

Kuvassa 5.8 on esitetty eri lämpötilavirheiden jakaumat sekä havaitun lämpötilan ja kahden metrin ennustetun lämpötilan jakaumat lämpötilan ennustevirheen suhteen. Huomaa, että kuvilla voi olla keskenään eri x- ja y-akselit. Lämpötilan ennustevirheen kuvista nähdään, että jakaumat ovat piirtyneet enimmäkseen yliennustustilanteista (punaiset) ja suhteellisen heikoista lämpötilan ennustevirheistä. Maan keskiosassa on näkyvissä myös vaaleansininen aliennustevirheen käyrä, mutta yhdessäkään kuvassa ei ole käyrää, joka kuvaa suurimpia aliennustevirheitä. Näin ollen rajatun datan voidaan sanoa kuvaavan tilanteita, jolloin säämallilla on suuri potentiaali yliennustaa lämpötiloja.

Havaitun lämpötilan ja kahden metrin ennustetun lämpötilan kuvia katsomalla nähdään, että ECMWF:n säämallin ennustaessa tällaisissa olosuhteissa alueelle hyvin kylmiä lämpötiloja, ovat ne todennäköisemmin yliennustettuja, maan keskiosassa mahdollisesti myös aliennustettuja. Jokaisella alueella -10 °C:een ja -20 °C:een väliin ennustetut lämpötilat voivat olla yliennustettujen ohella myös hyvin ennustettuja, kuten keltainen käyrä osoittaa. Kuvasta nähdään myös sama kuin koko datalla piirretystä kuvasta 5.4: kylmimmät ennustetut lämpötilat ovat liian lämpimiä verrattuna havaittuihin kylmimpiin lämpötiloihin.



Kuva 5.8: Inversiotilanteisiin rajatulla datalla saatu tulos lämpötilan ennustevirheen jakaumista sekä ennustetun lämpötilan ja havaitun lämpötilan jakaumista lämpötilan ennustevirheen suhteen. Huomaa kuvissa olevat erilaiset akselit. Nähdään kuinka lämpötilavirheen kuvista maan keskiosaa lukuunottamatta puuttuu aliennustevirheitä kuvaavat siniset käyrät. Tämä tarkoittaa oletuksen mukaisesti sitä, että data kuvaa olosuhteita, joissa yliennustustapaukset ovat todennäköisiä. Havaitaan myös sama kuin varsinaisen datan tapauksessa: säämallin ennustamat kylmimmät kahden metrin lämpötilat eivät ole yhtä kylmiä kuin kylmimmät havaitut lämpötilat.

Rajatun datan tapauksessa havaintoja on melko vähän, kuten nähdään taulukosta 5.2. Taulukossa on havaintojen lukumäärä kussakin luokassa ja alueessa rajatun datan tapauksessa. Luokassa 5 ei ole yhtään arvoa, luokassa 4 arvoja on vain maan keskiosassa. Luokissa 1, 2 ja 3 on arvoja, mutta etenkin luokassa 1 arvoja on jo niin vähän, että johtopäätöksiä ei voida kyseisen luokan osalta tehdä, samoin luokan 4 kohdalla. Näin ollen datan rajaaminen siten, että lämpötilan yliennustevirheet ovat todennäköisiä, on mahdollista. Vertaamalla taulukkoa 5.2 taulukkoon 4.1 nähdään, että tällä tavoin suurista yliennustevirheistä saadaan rajattua kuitenkin vain murto-osa.

Taulukko 5.2: Havaintojen lukumäärä kussakin luokassa alueittain, kun dataa on rajattu inversiolle suotuisiin olosuhteisiin. Taulukosta nähdään, että arvoja saadaan eniten kolmeen ensimmäiseen luokkaan, joista luokka 1 ja luokka 2 kuvaavat yliennustustilanteita. Siis rajatuissa olosuhteissa, missä vallitsee heikko tuuli, korkeapaine, kylmä ilmamassa ja havaittavan lämmön vuo suuntautuu pinnasta ilmakehään, yliennustustilanteet saadaan korostumaan, kuten alunperin oletettiin.

Luokka	Lämpötilavirheen väli ($^{\circ}\text{C}$)	Eteläosa	Keskiosa	Pohjoisosa
1]10, 14.65]	3	15	21
2]5, 10]	84	93	41
3]−5, 5]	238	383	64
4]−10, −5]	0	4	0
5]−9.35, −10]	0	0	0
Yht.	[−9.35, 14.65]	325	495	126

Lämpötilojen yliennustetarkastelun myötä voidaan havaita sama mikä empiirisesti ollan todettu luvussa 2: talvella korkeapaineen aikana heikkotuulisissa pakkastilanteissa lämpötiloihin liittyvät yliennustevirheet ovat todennäköisiä ja ne liittyvät usein inversio-tilanteisiin. Tämä tukee myös kirjallisuudessa tehtyjä havaintoja (Owens and Hewson, 2018).

6. Johtopäätökset

Ennustevirheen jakaumista huomataan, että mallimuuttujien jakaumat ennustevirheen suhteen ovat pääasiassa päällekkäin eikä eri suuruisten ennustevirhetilanteiden erottele ole useimpien mallimuuttujien kohdalla järkevää. Mallimuuttujia, joiden jakaumissa aliennustevirheet erottuvat muista jakauman käyristä kaikista selvimmin ovat pintapaine, inversioluku, ilmamassan lämpötila ja kymmenen metrin tuulen nopeus. Suuria aliennustevirheitä havaitaan käytännössä vähemmän kuin yliennustevirheitä, joten suurten aliennustevirheiden otoskoko on työssä käytetyssä datassa melko pieni. Tämän takia suurista aliennustevirheistä tehtyjä havaintoja ei voida pitää täysin luotettavina.

Yliennustamistilanteet eivät kovin monen mallimuuttujan kohdalla erotu muista jakaumista tuloksia tarkastellessa, vaikka alunperin näin oletettiin suurten ennustevirheiden liittyessä erityisesti lämpötilan yliennustustilanteisiin. Lämpötilan yliennustevirheet erottuvat parhaiten pintapaineen, kymmenen metrin tuulen nopeuden, inversioluvun, ilmamassan lämpötilan ja havaitun lämmön vuon kuvissa. Dataa rajaamalla näiden tulosten ja luvussa 2 tehtyjen empiiristen havaintojen perusteella lämpötilojen yliennustamistilanteet saatiin esille, mikä tukee käytännössä tehtyjä havaintoja muun muassa matalan kerroksen inversioihin liittyen. Lämpötilojen yliennustevirheet voivat kuitenkin johtua hyvin monesta asiasta, kuten luvussa 2 on todettu. Tällaisten tilanteiden tutkiminen pelkän data-analyysin keinoin voi olla melko hankalaa. Jatkotutkimuksena voisi tarkastella datan aikasarjaa ja rajata sitä esimerkiksi poistamalla suuret lämpötilan muutokset lyhyessä ajassa. Tällöin lauhtumiseen ja jäähtymiseen liittyvät virheet jäävät tarkastelun ulkopuolelle ja mallimuuttujien jakaumista voitaisiin löytää jonkinlaista apua erityisesti inversiotilanteiden aiheuttamien lämpötilavirheiden ennakkointiin.

Tulokset olisivat voineet olla erilaisia, jos tutkittaisiin muitakin kuin lineaarisia korrelaatiota tai käytettäisiin tekoälyalgoritmeja tutkimaan mallimuuttujien ja lämpötilan ennustevirheiden välisiä yhteyksiä ja erottelemaan dataa. Työssä tutkittiin alustavasti erilaisia luokkavälejä ja päädyttiin esitettyyn viisiluokkaiseen jaotteluun, jossa suhteellisen pienet ennustevirheet kuuluvat samaan luokkaan. Tuloksia voisi tutkia tarkemmin käyttäen erilaista luokkajakoa ja/tai suurempaa datamäärää pidemmältä ajanjaksolta. Joka tapauksessa lisätutkimusta tarvitaan. Tekoälyalgoritmien hyödyntäminen voisi tuoda uutta tietoa mallimuuttujien käyttäytymisestä ja antaa tutkimukselle uutta näkökulmaa.

7. Yhteenveto

Tässä työssä oltiin kiinnostuneita ECMWF:n säämallin kahden metrin lämpötilaennusteisiin liittyvistä suurista ennustevirheistä Suomessa talvisin. Työssä pyrittiin löytämään data-analyysin avulla ECMWF:n vuosien 2013-2017 talvikuukausien (joulukuu-helmikuu) sääennustusdatasta yhteyksiä suurten lämpötilan ennustevirheiden ja mallimuuttujien välille, jotta pystyttäisiin paremmin ennakkoon arvioimaan lämpötilaennusteeseen liittyvää virhettä. Käytössä oli joukko havaintoasemia, jotka jaoteltiin kolmeen osaan (etelä-, keski- ja pohjoisosa) Suomen 30 vuoden keskilämpötilan perusteella. Empiiristen havaintojen mukaan suuria lämpötilan ennustevirheitä syntyy yleensä pakkasjakson aikana, jolloin Suomessa on kylmää, vallitsee korkeapaine ja tuuli on heikkoa. Tällöin muodostuu usein matalan kerroksen inversioita, jolloin säämallin lämpötilat ovat laajalla alueella pidempikestoisesti yliennustettuja eli ennustettu liian lämpimiksi. Pilvipeitteessä tapahtuvat odottamattomat muutokset voivat aiheuttaa talvella paikallisesti sekä yli- että alennustevirheitä, sillä lämpötilan vuorokausivaihtelun ja auringon lämpösäteilyn puuttuessa esimerkiksi pilvipeitteen äkillinen repeileminen aiheuttaa lämpötilan yliennustevirheitä maasta lähtevän tehoisan ulossäteilyn kasvaessa. Hetkellisesti suuria ennustevirheitä voi liittyä sään lauhtumiseen tai pakkasen kiristymiseen, jolloin virhe useimmiten liittyy lauhtumisen tai jäähtymisen ajoitukseen.

Ymmärrettiin, että ECMWF:n säämallin kahden metrin lämpötilalaskentaan on tehty rajoituksia epäfysikaalisten tilanteiden välttämiseksi. Näistä rajoituksista johtuen säämallin kyky mallintaa hyvin stabiileja tilanteita on osin heikko, mistä johtuen erityisesti inversiotilanteiden mallintaminen tuottaa hankaluuksia, sillä tällöin maanpinnan läheisen kerroksen lämpötilaprofiili ei yleensä ole tarpeeksi jyrkkä. Tämä selittää datan ja havaintoaineiston perusteella tehtyjä havaintoja siitä, että suurimmat lämpötilan ennustevirheet liittyvät useimmiten nimenomaan yliennustustilanteisiin. Näin voitiin olettaa, että data-analyysivaiheessa yliennustustilanteet tulevat korostumaan niiden ollessa alennustevirheitä todennäköisempiä.

Korrelaatiotarkastelun avulla tutkittiin mallimuuttujien ja lämpötilavirheiden välistä yhteyttä. Tämän perusteella valittiin mallimuuttujia tarkempaa tiheysfunktioanalyysia varten, jossa ennustevirheet jaettiin viiteen luokkaan ja mallimuuttujien jakaumia tarkasteltiin näiden virheluokkien suhteen. Kaiken kaikkiaan eri ennustevirheiden jakaumat me-

nivät useimpien mallimuuttujien kohdalla päällekkäin enemmän kuin alunperin osattiin ajatella, minkä seurauksena toivottuja selviä eroja mallimuuttujien jakaumissa ennustevirheen suhteen nähtiin vähemmän. Suuria aliennustevirheitä kuvaavan luokan otoskoko oli muiden luokkien otoskokoon verattuna pieni, jolloin tulkinta suurten aliennustevirheidä ja ECMWF:n mallimuuttujien välillä jäi pinnalliseksi pienen otoskoon aiheuttaessa tuloksiin vääristymää. Jakaumien päällekkäisyyksistä huolimatta kuvien tarkalla tutkimisella huomattiin muutaman mallimuuttujan kohdalla sellaisia piirteitä, joiden perusteella dataa voitiin rajata lämpötilan yliennustustilanteiden tarkempaa tutkimista varten. Näitä tietoja hyväksikäyttäen onnistuttiin löytämään synoptiset olosuhteet, joissa ECMWF:n säämallilla on suuri taipumus yliennustaa lämpötiloja: heikko tuuli, korkeapaine, selkeä taivas ja kylmä ilmassa, joka johtaa myös kylmiin lämpötiloihin maanpinnalla. Nämä löydöt vastaavat empiirisesti havaittuja olosuhteita ja kirjallisuudessa tehtyjä havaintoja (Hyrkkänen et al., 2015; Haiden et al., 2018, 2014b).

Lopuksi voidaan todeta, että tämä aihealue vaatii vielä lisätutkimusta. Koneoppimismenetelmiä hyödyntämällä voidaan mahdollisesti kehittää menetelmiä suurten lämpötilan ennustevirheiden korjaamiseksi. Suuret lämpötilan ennustevirheet eivät kuitenkaan aina liity tietyn tyyppiseen säähän tai synoptiseen tilanteeseen, joten kauaskantoisempi ratkaisu tulee muun muassa säämallin kahden metrin lämpötilaan liittyvän algoritmin, eli säämallin fysiikan kehittämisestä.

Kiitokset

Leila Hieta, kiitokset ohjauksesta, oivaltavista kommenteista, sekä tuesta kuvaajien ja materiaalien kanssa.

Ilmatieteen laitos, kiitokset työn taloudellisesta tukemisesta, datan ja havaintoaineiston tarjoamisesta.

Kirjallisuutta

- AMS Glossary (2012). Surface radiation budget. http://glossary.ametsoc.org/wiki/Surface_radiation_budget. Viitattu: 10.3.2019.
- Arduini, G. (2019). Impact of a multi-layer snow model in the ecmwf integrated forecasting system. *APPLICATE General Assembly 2019*.
- Breheny, P. (2010). Kernel density estimation. <https://web.as.uky.edu/statistics/users/pbreheny/621/F10/notes/10-28.pdf>. Viitattu: 10.3.2019.
- ECMWF (2009). *Part IV: Physical Processes*. Number 4 in IFS Documentation. ECMWF. Operational implementation 3 June 2008.
- ECMWF (2016). New forecast model cycle brings highest-ever resolution. <https://www.ecmwf.int/en/about/media-centre/news/2016/new-forecast-model-cycle-brings-highest-ever-resolution>. Viitattu: 27.2.2019.
- ECMWF (2019). Parameter details in grib parameter database. <https://apps.ecmwf.int/codes/grib/param-db?id=146>. Viitattu: 27.2.2019.
- Finnish Meteorological Institute (2018). Application and verification of ecmwf products 2018. <https://www.ecmwf.int/sites/default/files/elibrary/2018/18562-application-and-verification-ecmwf-products-2018-finland.pdf>. Vuositainen raportti ECMWF:lle.
- Glahn, H. R. and Lowry, D. A. (1972). The use of model output statistics (mos) in objective weather forecasting. *Journal of Applied Meteorology*, 11(8):1203–1211.
- Haiden, T., Forbes, R., Ahlgrimm, M., and Bozzo, A. (2015). The skill of ecmwf cloudiness forecasts. *ECMWF Newsletter*, pages 14–19. Newsletter No. 143 - Spring 2015.
- Haiden, T., Janousek, M., Bauer, P., Bidlot, J., Ferranti, L., Hewson, T., Prates, F., Richardson, D., and Vitart, F. (2014a). Evaluation of ecmwf forecasts, including 2013-2014 upgrades. Sisäinen raportti ECMWF:n ja Ilmatieteen laitoksen välillä. Lupa viittaamiseen kysytty ECMWF:ltä.

- Haiden, T., Prates, F., Sandu, I., and Balsamo, G. (2014b). 2-m temperature under very stable conditions. ECMWF Technical Memorandum.
- Haiden, T., Sandu, I., Balsamo, G., Arduini, G., and Beljaars, A. (2018). Addressing biases in near-surface forecasts. *ECMWF Newsletter*, pages 20–25. Newsletter No. 157 - Autumn 2018.
- Heidorn, K. C. (2012). The temperature inversion. <http://www.islandnet.com/~see/weather/elements/inversion.htm>. Viitattu: 27.2.2019.
- Hewson, T. (2019). Known ifs forecasting issues. <https://confluence.ecmwf.int/pages/viewpage.action?pageId=28328424>. ECMWF Forecast User Portal. Viitattu: 11.3.2019.
- Holton, J. R. and Hakim, G. J. (2013). *An introduction to dynamic meteorology*. Elsevier Academic Press, Burlington, MA.
- Hyrkkänen, J., Kilpinen, J., Nurmi, P., Kaurola, J., and Brockmann, M. (2015). Error characteristics of temperature forecast in finland for the period 1979-2011 in relation to various weather patterns. *Meteorological Applications*, 23(2):244–253.
- Karttunen, H., Koistinen, J., Saltikoff, E., and Manner, O. (2008). *Ilmakehää, sää ja ilmasto*. Ursa.
- Kelleher, A. (2016). If correlation doesn't imply causation, then what does? <https://medium.com/causal-data-science/if-correlation-doesnt-imply-causation-then-what-does-c74f20d26438>. Viitattu 20.3.2019.
- Laerd Statistics (2018). Pearson product-moment correlation. <https://statistics.laerd.com/statistical-guides/pearson-correlation-coefficient-statistical-guide.php>. Viitattu: 10.3.2019.
- Magnusson, L. and Källén, E. (2013). Factors influencing skill improvements in the ecmwf forecasting system. *Monthly Weather Review*, 141(9):3142–3153.
- Mahrtand, L. and Vickers, D. (2002). Contrasting vertical structures of the stable boundary layer. page 4.
- NASA (1999). Clouds and the energy cycle. *The Earth Science Enterprise Series*. Viitattu: 27.2.2019.
- Owens, R. G. and Hewson, T. D. (2018). Screen level temperatures and moisture. ECMWF Forecast User Guide, Chapter 9.2. Viitattu: 19.3.2019.

- Pirinen, P., Simola, H., Aalto, J., Kaukoranta, J.-P., Karlsson, P., and Ruuhela, R. (2012). Tilastoja suomen ilmastosta 1981-2010.
- Räisänen, J. and Heino, R. (2008). *Klimatologian perusteita*.
- Ritter, M. E. (2016). The physical environment: an introduction to physical geography. https://www.earthonlinemedia.com/ebooks/tpe_3e/energy/energy_balance.html. Viitattu: 10.3.2019.
- Stull, R. B. (1988). *An introduction to boundary layer meteorology*. Kluwer Academic Publishers, Boston.
- Trenberth, K. E., Fasullo, J. T., and Kiehl, J. (2009). Earth's global energy budget. *Bulletin of the American Meteorological Society*, 90(3):311–324.
- van Meijgaard, E., van Uft, B., van de Berg, W. J., Bosveld, F. C., van den Hurk, B., Lenderink, G., and Siebesma, A. P. (2008). The knmi regional atmospheric climate model racmo version 2.1. Technical report, KNMI.

A. Asemien tiedot

Asemajoukkoluettelo erikseen jokaiselle tutkitulle alueelle. Kunkin aseman tiedoista löytyy WMO-numero, aseman nimi, aseman korkeus merenpinnasta ja aseman sijainnin koordinaatit eli pituus- ja leveyspiiri.

Taulukko A.1: Eteläosan asemajoukon tiedot

WMO-numero	Nimi	Korkeus	Pituuspiiri	Leveyspiiri
2773	Turku Artukainen	8	22.179	60.454
2828	Kaarina Yltöinen	6	22.552	60.387
2906	Kemiönsaari Kemiö	12	22.758	60.171
2750	Hanko Tvärminne	3	23.248	59.844
2963	Jokioinen Ilmala	104	23.498	60.814
2949	Somero Salkola	142	23.806	60.647
2777	Salo Kiikala lentokenttä	117	23.65	60.464
2756	Salo Kärkkä	2	23.113	60.374
2706	Lohja Porla	36	24.05	60.244
2704	Hattula Lepaa	87	24.324	61.115
2754	Hämeenlinna Katinen	87	24.492	60.999
2829	Hyvinkää Hyvinkäänkylä	86	24.803	60.596
2998	Helsinki Kumpula	24	24.961	60.203
2978	Helsinki Kaisaniemi	4	24.945	60.175
2974	Vantaa Helsinki-Vantaan lentoasema	51	24.957	60.327
2759	Porvoo Harabacka	22	25.607	60.392
2830	Kouvola Anjala	33	26.811	60.696
2956	Kouvola Utti Lentoportintie	99	26.929	60.891
2959	Lappeenranta Lepola	103	28.209	61.058
2733	Lappeenranta Konnunsuo	46	28.564	61.039
2734	Parikkala Koitsanlahti	74	29.461	61.445
2768	Heinola Asemantaus	92	26.05	61.2
2965	Lahti Laune	78	25.631	60.962
2713	Hämeenlinna Lammi Evo	134	25.133	61.217
2708	Karvia Alkkia	161	22.8	62.183
2937	Kokemäki Tulkila	38	22.346	61.253
2944	Pirkkala Tampere-Pirkkala lentoasema	112	23.618	61.418
2763	Tampere Härmälä	84	23.747	61.466
2718	Puumala kirkonkylä	98	28.185	61.522

Taulukko A.2: Keskiosan asemajoukon tiedot

WMO-numero	Nimi	Korkeus	Pituuspiiri	Leveyspiiri
2725	Halsua Purola	153	24.444	63.446
2735	Virrat Äijänneva	138	23.542	62.328
2736	Juva Partala	110	27.885	61.892
2737	Toholampi Laitala	83	24.163	63.821
2738	Pyhäjärvi Ojakylä	152	25.706	63.736
2739	Sotkamo Kuolaniemi	161	28.336	64.112
2755	Ylivieska lentokenttä	76	24.725	64.05
2766	Ilomantsi Pötsönvaara	235	31.044	63.142
2770	Juupajoki Hyytiälä	153	24.287	61.846
2771	Joutsa Savenaho	146	26.095	61.879
2778	Savonlinna Punkaharju Laukansaari	78	29.315	61.802
2787	Alajärvi Möksy	171	24.261	63.089
2791	Juuka Niemelä	115	29.234	63.232
2796	Liekka Lampela	98	30.046	63.321
2803	Siikajoki Ruukki	48	25.089	64.684
2832	Tohmajärvi Kemie	90	30.347	62.235
2833	Seinäjoki Pelmaa	26	22.489	62.938
2834	Viermä Kaarakkala	206	27.221	63.841
2850	Varkaus Kosulanniemi	83	27.908	62.322
2883	Kajaani Petäisenniska	160	27.752	64.217
2903	Kruunupyy Kokkola-Pietarsaari lentoasema	25	23.139	63.721
2913	Kauhava lentokenttä	42	23.044	63.12
2915	Viitasaari Haapaniemi	130	25.859	63.082
2935	Jyväskylän lentoasema	139	25.671	62.398
2939	Ilomantsi Mekrijärvi	155	30.975	62.77
2945	Jämsä Halli lentoasema	143	24.805	61.855
2947	Mikkeli lentoasema	99	27.202	61.689
2955	Kuopio Savilahti	87	27.633	62.893

Taulukko A.3: Pohjoisosan asemajoukon tiedot

WMO-numero	Nimi	Korkeus	Pituuspiiri	Leveyspiiri
2866	Pudasjärvi lentokenttä	120	26.963	65.4
2804	Taivalkoski kirkonkylä	197	28.218	65.575
2869	Kuusamo lentoasema	264	29.227	65.993
2811	Kuusamo Kiutaköngäs	165	29.312	66.37
2881	Ranua lentokenttä	161	26.368	65.977
2864	Kemi Kemi-Tornio lentoasema	10	24.579	65.78
2880	Tornio Torppi	8	24.174	65.847
2847	Rovaniemi rautatieasema	85	25.709	66.498
2814	Kemijärvi lentokenttä	208	27.159	66.716
2849	Salla kirkonkylä	215	28.674	66.834
2745	Salla Naruska	213	29.178	67.162
2815	Savukoski kirkonkylä	180	28.177	67.286
2719	Sodankylä Lokka	240	27.746	67.822
2816	Sodankylä Vuotso	248	27.185	68.084
2722	Inari Saariselkä matkailukeskus	302	27.413	68.415
2807	Inari Ivalo lentoasema	140	27.419	68.613
2835	Inari Nellim	121	28.299	68.849
2702	Inari Kaamanen	156	27.266	69.141
2857	Inari Angeli Lintupuoliselkä	285	25.736	68.903
2858	Inari Kirakkajärvi	106	28.894	69.582
2825	Utsjoki Nuorgam	22	27.897	70.082
2805	Utsjoki Kevo	107	27.007	69.756
2717	Kittilä Pokka	275	25.783	68.17
2844	Pello kirkonkylä	85	23.963	66.773
2812	Ylitornio Meltosjärvi	93	24.65	66.53
2860	Kittilä kirkonkylä	181	24.902	67.652
2720	Kittilä lentoasema	193	24.855	67.693
2726	Enontekiö Näkkälä	374	23.576	68.603
2801	Enontekiö Kilpisjärvi kyläkeskus	480	20.791	69.049
2859	Puolanka Paljakka	341	28.057	64.664
2799	Kuhmo Kalliojoki	196	30.171	64.298
2889	Suomussalmi Pesio	222	28.747	64.931
2714	Vaala Pelso	114	26.424	64.501